



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

ULB

# Identifikation des Fahrfertigkeitsniveaus von Motorradfahrern in Kurvenfahrt im Realverkehr

Magiera, Nils  
(2020)

DOI (TUprints): <https://doi.org/10.25534/tuprints-00014011>

Lizenz:



CC-BY-SA 4.0 International - Creative Commons, Attribution Share-alike

Publikationstyp: Ph.D. Thesis

Fachbereich: 16 Department of Mechanical Engineering

Quelle des Originals: <https://tuprints.ulb.tu-darmstadt.de/14011>

---

---

# **Identifikation des Fahrfertigkeitsniveaus von Motorradfahrern in Kurvenfahrten im Realverkehr**

Vom Fachbereich Maschinenbau an der  
Technischen Universität Darmstadt  
zur Erlangung des Grades eines  
Doktor-Ingenieurs (Dr.-Ing.)  
genehmigte

## **Dissertation**

vorgelegt von

**Nils Magiera, M. Sc.**  
aus Offenbach am Main

Berichterstatter: Prof. Dr. rer. nat. Hermann Winner

Mitberichterstatter: Prof. Dr.-Ing. Jürgen Adamy

Tag der Einreichung: 12.05.2020

Tag der mündlichen Prüfung: 01.07.2020

Darmstadt 2020

D 17

---

Dieses Dokument wird bereitgestellt von TUpriints – Publikationsservice der TU Darmstadt.

<https://tuprints.ulb.tu-darmstadt.de/>

Bitte verweisen Sie auf:

URN: <urn:nbn:de:tuda-tuprints-140111>

URI: <https://tuprints.ulb.tu-darmstadt.de/id/eprint/14011>

Lizenz: CC BY-SA 4.0 International

<https://creativecommons.org/licenses/by-sa/4.0/deed.de>

---

# Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Fachgebiet Fahrzeugtechnik (FZD) der Technischen Universität Darmstadt. Die Inhalte der Dissertation wurden im Rahmen einer Forschungs Kooperation mit der Honda Research Institute Europe GmbH erarbeitet.

Ein besonderer Dank gilt meinem Doktorvater Herrn Prof. Dr. rer. nat. Hermann Winner, der mit kritischen Diskussionen, großen Freiräumen und Vertrauen in meine Person entscheidend zum Gelingen dieser Arbeit beigetragen hat.

Herrn Prof. Dr.-Ing. Jürgen Adamy, Leiter des Fachgebiets Regelungsmethoden und Robotik (rmr) der Technischen Universität Darmstadt, danke ich für die freundliche Übernahme des Korreferats.

Bei den Projektpartnern des Honda Research Institute Europe möchte ich mich für die Finanzierung, die Unterstützung im Projekt aber auch die stets angenehme Zusammenarbeit bedanken. Mein Dank gilt besonders meinem Ansprechpartner und Betreuer Herbert Jansen, der mir stets mit Rat und Tat zur Seite stand. Ebenfalls danken möchte ich Dr. Martin Heckmann für den Austausch und die Diskussionen rund um die Themen der Segmentierung der Messdaten und Oliver Fuchs für die Bereitstellung des Versuchsfahrzeugs.

Darüber hinaus bedanke ich mich bei allen Mitarbeitern des Fachgebiets Fahrzeugtechnik, einschließlich der Werkstatt und dem Sekretariat. Die angenehme Arbeitsatmosphäre und das kollegiale Miteinander werden mir in guter Erinnerung bleiben.

Ganz besonders danken möchte ich auch meinen Eltern Harald und Carmen die mich während meiner kompletten universitären Laufbahn stets unterstützt haben und mich meine eigenen Entscheidungen treffen ließen.

Nils Magiera

Stuttgart, Mai 2020



---

---

# Inhaltsverzeichnis

<b>Vorwort .....</b>	<b>III</b>
<b>Inhaltsverzeichnis .....</b>	<b>V</b>
<b>Abkürzungen.....</b>	<b>IX</b>
<b>Formelzeichen und Indizes .....</b>	<b>X</b>
<b>Abbildungen und Tabellen .....</b>	<b>XII</b>
<b>Kurzzusammenfassung .....</b>	<b>XVII</b>
<b>1 Motivation.....</b>	<b>1</b>
1.1 Aufbau der Arbeit .....	4
<b>2 Stand der Forschung und Technik.....</b>	<b>5</b>
2.1 Grundlagen .....	5
2.1.1 Koordinatensysteme .....	5
2.1.2 Kurvenfahrt von Einspurfahrzeugen .....	6
2.1.3 Begriffsdefinition Fahrfertigkeit .....	8
2.2 Fahrermodellierung .....	9
2.2.1 Indirekte statistische Fahrfertigkeitsmodelle .....	9
2.2.2 Manöverbasierte Bewertung des Fahrerverhaltens .....	13
2.3 Ableitung des Forschungsbedarfs.....	19
<b>3 Untersuchungswerkzeuge &amp; Methoden .....</b>	<b>21</b>
3.1 Versuchsfahrzeug.....	21
3.1.1 Messtechnik.....	21
3.1.2 Messdaten-Vorverarbeitung .....	23
3.1.3 Video-Synchronisation .....	24
3.2 Bestimmung der Position im Fahrstreifen .....	25
3.3 Versuchsstrecke .....	34
3.4 Probandenkollektiv .....	35
<b>4 Segmentierung der Kurvenfahrt .....</b>	<b>37</b>
4.1 Motivation .....	37
4.2 Einordnung der Manöver-Primitive in bestehende Verhaltensmodelle .....	40
4.3 Definition der Manöverzerlegung .....	41
4.4 Segmentierungsverfahren .....	43
4.4.1 Grundlagen.....	44

4.4.2	Hierarchisches Hidden-Markov-Modell .....	48
4.4.3	Schwellwertbasiertes Hidden-Markov-Modell .....	50
4.4.4	Plausibilisierung & Nachverarbeitung .....	52
4.5	Evaluationsmetriken .....	54
4.5.1	Zeitliche Label-Konformität .....	54
4.5.2	Bewertung der Segmentübergänge .....	56
4.6	Ergebnisse .....	59
4.6.1	Hierarchisches Hidden-Markov-Modell .....	59
4.6.2	Schwellwertbasiertes Hidden-Markov-Modell .....	64
4.6.3	Vergleich der Segmentierungsverfahren .....	65
4.6.4	Potential individueller Segmentierungsmodelle .....	68
4.7	Zwischenfazit Manöversegmentierung .....	69
<b>5</b>	<b>Methoden zur Bewertung der stationären Kurvenfahrt .....</b>	<b>71</b>
5.1	Hypothesenbildung .....	71
5.2	Rollbewegung .....	75
5.2.1	Frequenzbasierte Kennwerte .....	75
5.2.2	Regressionsbasierte Kennwerte .....	79
5.2.3	Skalierung der Kennwerte .....	82
5.2.4	Zwischenfazit zur Arbeitshypothese .....	83
5.3	Fahrfehlerkorrekturen .....	86
5.3.1	Ursache und Muster von Fahrfehlern .....	86
5.3.2	Fahrfehlerdetektion .....	88
5.3.3	Zwischenfazit zur Arbeitshypothese .....	93
5.4	Linienwahl .....	95
5.4.1	Häufigkeitsverteilung Linienwahl .....	95
5.4.2	Positionsvariation und Positionsverschiebung .....	100
<b>6</b>	<b>Methoden zur Bewertung nicht-stationärer Kurvenfahrt .....</b>	<b>104</b>
6.1	Frequenzselektierendes Filterverfahren .....	107
6.1.1	Filterverfahren .....	107
6.1.2	Optimierung der Grenzfrequenzen .....	108
6.2	Regressionsbasiertes Verfahren .....	109
6.2.1	Regressionsmodelle .....	109
6.3	Zwischenfazit .....	112
<b>7</b>	<b>Bewertung der Klassifikation fahrerindividueller Fahrfertigkeitsniveaus .....</b>	<b>115</b>
7.1	Untersuchungsmethodik .....	116
7.1.1	Zufallsexperiment zur Datengenerierung .....	116
7.1.2	Diskriminanzanalyse .....	117
7.1.3	Clusteranalyse .....	118
7.2	Definition der Fahrfertigkeitsniveaus .....	121
7.2.1	Rollbewegung in stationäre Kurvenfahrt .....	121

---

7.2.2	Fahrfehlerkorrekturen in stationärer Kurvenfahrt.....	123
7.2.3	Linienwahl in stationärer Kurvenfahrt.....	125
7.2.4	Rollbewegung des Einlenkvorgangs.....	126
7.2.5	Reflektion der Beobachtungen.....	128
7.3	Auswirkungen des Stichprobenumfangs & Indikatorenkombination.....	129
7.3.1	Identifikation des Fahrfertigkeitsniveaus anhand der Rollbewegung.....	129
7.3.2	Identifikation des Fahrfertigkeitsniveaus anhand Indikatoren aus Fahrfehlerdetektions- und Linienwahl.....	134
7.3.3	Klassifikation der Fahrfertigkeiten beim Einlenken.....	135
7.4	Diskussion der Ergebnisse.....	137
<b>8</b>	<b>Fazit und Ausblick .....</b>	<b>139</b>
<b>A</b>	<b>Datenaufnahme und Vorverarbeitung .....</b>	<b>142</b>
A.1	Versuchsfahrzeug.....	142
A.2	Video Synchronisation.....	143
A.3	Berechnung der Position im Fahrstreifen.....	144
A.3.1	Heuristik zur Zuordnung der erkannten Linien zu den Fahrstreifenmarkierungen.....	144
A.3.2	Analyse der Fahrstreifen-Positionsschätzung.....	145
<b>B</b>	<b>Messdaten Segmentierung.....</b>	<b>146</b>
B.1	Definition der Manöver-Primitive.....	146
B.2	Abfolge der Manöver-Primitive:.....	147
B.3	Unschärfe der Segmentierungspunkte.....	147
B.4	HHMM Modelparameter.....	148
B.5	Plausibilisierung der HMM Manöverabfolge.....	148
B.6	Ergebnisse der Auswertung der Segmentierungsgüte.....	149
<b>C</b>	<b>Metriken zu Bewertung der Kurvenfahrt.....</b>	<b>151</b>
C.1	Impulsantwort Bandpassfilter.....	151
C.2	Korrelation zw. Kennwerten und Metadaten.....	152
C.3	Ergebnisse der statistischen Tests der Verteilungen.....	154
C.4	Frequenzoptimierung zur Bewertung dynamischer Rollbewegung.....	157
C.5	Kennwertverteilungen der Bewertung des Aufrichtens.....	158
C.6	Fahrerindividuelle Kennwertverteilungen.....	159
C.6.1	Rollbewegung in stationärer Kurvenfahrt.....	159
C.6.2	Fahrfehlerkorrekturen in stationärer Kurvenfahrt.....	160
C.6.3	Linienwahl in stationärer Kurvenfahrt.....	160
C.6.4	Rollbewegung beim Einlenken.....	161
C.6.5	Rollwinkelverteilung.....	162
C.6.6	Dreistufiges Fahrfertigkeitsmodell für die stationäre Kurvenfahrt.....	162
	<b>Literaturverzeichnis .....</b>	<b>163</b>

<b>Eigene Veröffentlichungen .....</b>	<b>171</b>
<b>Betreute studentische Arbeiten.....</b>	<b>172</b>

---

# Abkürzungen

Abkürzung	Beschreibung
ACC	Accuracy
BP	Bandpass
BMVI	Bundesministerium für Verkehr und digitale Infrastruktur
CLAHE	Contrast-limited adaptive histogram equalization
CNN	Convolutional Neural Network
DFT	Diskrete Fourier-Transformation
DLC	Double Lane Change
EM	Expectation-Maximization
ENU	East-North-Up
FM	Fahrstreifen Markierung
FN	False Negative
FP	False Positive
FPR	False Positive Rate
GDV	Gesellschaft der Versicherer
GMM	Gaussian Mixture Model
HHMM	Hierarchisches Hidden-Markov-Modell
HMM	Hidden-Markov-Modell
IMU	Inertial Messeinheit
IoU	Intersection over Union
kNN	k-Nearest-Neighbor
LCIC	Lane Change In Curve
LI / LO	Left In / Left Out
LR / RL	Left to Right / Right to Left
MLP	Multi-Layer Perceptron
MP	Manöver Primitive
Pos	Position
Prob	Proband
PPV	Positive Predicted Value
RI / RO	Right In / Right Out
RMSE	Root-Mean Square Error
RNN	Recurrent Neural Network
SHMM	Schwellwertbasiertes Hidden-Markov-Modell
SR / SL	Stationary Right / Stationary Left
SVM	Support Vektor Maschine
TRM	Trajektorien Regressionsmodell
TP	True Positive
TPR	True Positive Rate
Var	Variante
WT	Wavelet Transformation

# Formelzeichen und Indizes

Symbol	Einheit	Beschreibung
$a$	m/s <sup>2</sup>	Beschleunigung
$A$	-	HMM - Zustandsübergangsmatrix
$b$	px	Brennweite in Pixel
$B$	-	HMM - Beobachtungsmatrix
$c$	-	Koeffizienten
$d$	m	Abstand
$D$	-	Distanzmaß
$exp$	-	Exponent
$f$	Hz	Frequenz
$g$	m/s <sup>2</sup>	Erdbeschleunigung
$G$	-	Regressionsmodell mit einer Glockenkurve
$j$	m/s <sup>3</sup>	Ruck
$K$	-	Kennwert
$k$	-	Knotenpunkt eines Spline Regressionsmodells
$l$	m	Radstand
$m$	-	Steigung
$M$	-	Anzahl
$N$	-	Anzahl
$p$	-	Wahrscheinlichkeit
$r$	m	Radius
$R$	-	Rotationsmatrix
$R^2$	-	Bestimmtheitsmaß
$s$	m	Weg
$S$	-	Spline Regressionsmodell
$t$	s	Zeit
$T$	-	Translationsvektor
$v$	m/s	Geschwindigkeit
$V$	-	Hellwert eines Bildpunkts im HSV Raum
$x,y,z$	-	Position
$\alpha$	-	HMM – Zustandsübergangswahrscheinlichkeit
$\beta$	-	HMM - Beobachtungswahrscheinlichkeit
$\delta$	-	HMM - Verbundwahrscheinlichkeit
$\varepsilon$	°	Lenkkopfwinkel
$\theta$	°	Nickwinkel
$\rho$	-	Pearson Korrelationskoeffizient
$\kappa$	1/m	Krümmung
$\lambda$	-	HMM - Modellparameter
$\mu$	-	Reibwertkoeffizient
$\pi$	-	HMM - Anfangswahrscheinlichkeiten
$\varphi$	°	Rollwinkel
$\psi$	-	HMM - Zustand
$X$		

---

<b>Index</b>	<b>Beschreibung</b>
A	Aufrichten aus Kurvenfahrt
au	außen / nach außen
besch	beschleunigen
brems	bremsen
$\Delta$ Pos	Verschiebung der Position
e	erdfest
E	Einlenken
f	fahrzeugfest
Elem	Element
Fen	Fenster
FK	Fahrfehlerkorrektur
Freq	Frequenzbasiert
h	hinten
hor	horizontalisiert
in	innen / nach innen
Kam	Kamera
Kontur	Reifenkontur
li	links
lim	limitiert
LW	Linienwahl
mi	mitte
Mot	Motorrad
Norm	normiert
optZent	optisches Zentrum
Pix	Pixel
Pos	Position
Rad	Rad
RB	Rollbewegung
re	rechts
Ref	Referenz
Reg	Regressionsbasiert
RWab	Rollwinkelabbau
RWauf	Rollwinkelaufbau
S	Schwerpunkt
Sen	Sensor
Seq	Sequenz(en)
th	theoretisch
v	vorne
vh	Vorderrad horizontalisiert
Well	Welligkeit
x	x-Richtung des Koordinatensystems
y	y-Richtung des Koordinatensystems
z	z-Richtung des Koordinatensystems



# Abbildungen und Tabellen

Abbildung 1-1: Lokalisierung und Kategorisierung von Alleinunfälle <sup>4,5</sup> .....	1
Abbildung 2-1: Verwendete Koordinatensysteme und deren Orientierung zueinander, eigene Darstellung .....	6
Abbildung 2-2: Rollgleichgewicht in stationärer Kurvenfahrt <sup>17</sup> .....	6
Abbildung 2-3: Fahrfertigkeitszuordnung mittels <i>g-g</i> -Diagramm nach Spiegel <sup>24</sup> .....	10
Abbildung 2-4: Mittlere Fahrstreifenposition für verschiedene Fahrerfahrungsklassen ...	13
Abbildung 2-5: Position im Fahrstreifen für einzelne Segmente aller Rechtskurven .....	13
Abbildung 3-1: Architektur des Messtechnikaufbaus des Versuchsfahrzeugs .....	21
Abbildung 3-2: Vergleich ungefilterter und vorverarbeiteten Daten für Rollwinkel und Rollrate.....	24
Abbildung 3-3: ①: Grauwertbild des blauen Kanals des RGB-Bildes. ②: Grauwertbild des V-Kanals des in den HSV-Farbraum transformierten RGB-Bildes. ③: Binärbild aus den Farbraum-Merkmalen von ①&②. ④: Mittels Sobel-Operator extrahierte Kantenmerkmale aus ②. ⑤: Aus Kantendetektion abgeleitetes Binärbild der Fahrstreifenmarkierungen. ⑥: Originalbild mit überlagerten Detektionen für Fahrstreifenmarkierungen.....	27
Abbildung 3-4: Approximation des Fahrstreifenverlauf basierend auf lokalen Gradienten der Fahrstreifenmarkierungen. Oben: Darstellung der Fahrstreifenmarkierungen in x-y-Koordinaten. Unten: Lokale Gradienten der gefensterten Fahrstreifenmarkierungen sowie approximierter Verlauf mittels Spline-Modell..	30
Abbildung 3-5: Entfernung der Fahrzeugposition zu den drei Fahrstreifenmarkierungen für eine exemplarische Versuchsfahrt der Probandenstudie .....	32
Abbildung 3-6: Ermittelte Krümmung der Fahrstreifenmarkierung im Vergleich zu der im Versuch gemessenen gefahrenen Kurvenkrümmung .....	33
Abbildung 3-7: Visualisierung und Lage der Versuchsstrecken A und B im Odenwald ...	34
Abbildung 3-8: Übersicht Kennwerte der Versuchsstrecken .....	34
Abbildung 4-1: Messdaten der Fahrzeugdynamik für drei unterschiedliche Kurvenfahrten (grau hinterlegt). (a): 60 ° Kurve, (b): 100 ° Kurve, (c) S-Kurve .....	38
Abbildung 4-2: Drei-Ebenen-Modelle nach Rasmussen und Donges <sup>93</sup> .....	40
Abbildung 4-3: Phasendiagramm der Manöver-Primitive .....	41
Abbildung 4-4: Segmentierung einer exemplarischen Testfahrt mit Links- und S-Kurve	43
Abbildung 4-5: Modellstruktur des hierarchischem HMM-Ansatzes .....	48
Abbildung 4-6: Exemplarische Darstellung von Übersegmentierung und Falsch-Segmentierung aufgrund schwellwertbasierter Segmentierung.....	50
Abbildung 4-7: Modellstruktur des schwellwertbasierten Segmentierungsverfahren mit HMM Klassifikation .....	51
Abbildung 4-8: Auftretende Fehlersegmentierungen. ①: Positionsänderung vor der Kurvenfahrt wird als Einlenken klassifiziert, dies hat zur Konsequenz, dass das eigentliche Einlenken als Richtungswechsel interpretiert wird. ②,③: Positionsänderungen im Anschluss an die Kurvenfahrt werden als Auslenken klassifiziert, was zur Folge hat, dass der eigentliche Auslenkvorgang als Richtungswechsel interpretiert wird. ....	52
Abbildung 4-9: Exemplarische Konfusionsmatrix zur Beurteilung der Segmentierungsergebnisse basierend auf einer erfassten und annotierten Messreihe .....	55
Abbildung 4-10: Verfahren zur Bewertung der Segmentübergänge nach Gensler und Sick, eigene Darstellung .....	56
Abbildung 4-11: Gegenüberstellung visueller Probandensegmentierung und Experten-Referenz zur Bestimmung der zeitlichen Segmentierungszonen-Größe .....	58

---

Abbildung 4-12: Vergleich der Segmentierungsgüte verschiedener Varianten des HHMM-Segmentierungsverfahren.....	61
Abbildung 4-13: Einfluss der Signalglättung auf das HHMM-Segmentierungsverfahren.....	63
Abbildung 4-14: Einfluss des Schwellwerts der Rollrate auf das S-HMM Segmentierungsverfahren .....	64
Abbildung 4-15: Vergleich der Bewertung der Segmentübergänge für HHMM und SHMM .....	66
Abbildung 4-16 Konfusionsmatrizen der Klassifikationsergebnisse auf Manöverebene, Ergebnisse in Prozent.....	67
Abbildung 5-1 Rollwinkel und Rollrate während stationärer Kurvenfahrt für Fahrer unterschiedlichen Fahrfertigkeitsniveaus.....	72
Abbildung 5-2: Ermittelter Abstand des Vorderradaufstandspunkt zur kurveninneren, hier rechten, Fahrstreifenmarkierung während stationärer Kurvenfahrt für Fahrer unterschiedlichen Fahrfertigkeitsniveaus.....	73
Abbildung 5-3: Optimierung der oberen und unteren Grenzfrequenz des Bandpassfilters der frequenzbasierten Auswertung für den Kennwert $KRB$ , $Freq$ , $\varphi$ .....	77
Abbildung 5-4: Kennwerteverteilung des frequenzbasierten Verfahrens auf dem nach Oszillationsstärke klassifizierten Testdatensatz.....	78
Abbildung 5-5: Verlauf einer "runden" Kurve; Approximation des Verlaufen mittels eines linearen Regressionsmodells.....	79
Abbildung 5-6: Bewertung des Testdatensatzes mit regressionsbasiertem Verfahren. Rechts: Gegenüberstellung der Verteilung von Kurvenfahren mit niedriger bzw. hoher Rollratenvariation .....	82
Abbildung 5-7: Kennwertverteilungen der stationären Kurvenfahrt gruppiert nach subjektiven Referenzeinteilung des Fahrfertigkeitsniveaus. In durchgezogen und fett dargestellt: Linkskurven. Gestrichelt und dünn dargestellt: Rechtskurven .....	84
Abbildung 5-8: Exemplarische Fahrfehlerkorrektur nach außen .....	86
Abbildung 5-9: Exemplarische Fahrfehlerkorrektur nach innen .....	87
Abbildung 5-10: Subsegmentierung der stationären Kurvenfahrt und Merkmalsextraktion .....	89
Abbildung 5-11: Aufbau eines Multi-Layer-Perceptrons mit zwei Ausgangssignalen zur binären Klassifikation .....	91
Abbildung 5-12: Kumulierte Häufigkeitsverteilung des Grades der Klassenzugehörigkeit für die drei Klassen des Trainingsdatensatz zur Erkennung von fehlerhaften Einlenkvorläufen. Ebenfalls, in gestrichelter Linie, dargestellt sind die Häufigkeitsverteilungen einer vergleichbaren binären Klassifikation, wie sie jedoch nicht gewollt ist.....	92
Abbildung 5-13: Kennwertverteilungen der Fahrfehlerdetektion gruppiert nach subjektiver Referenzeinteilung des Fahrfertigkeitsniveaus. Durchgezogen und fett dargestellt: Linkskurven. Gestrichelt und dünn dargestellt: Rechtskurven .....	93
Abbildung 5-14: Exemplarische Verläufe der Querablage für fehlerfreie Kurvenfahrten. a) Folgen des Fahrbahnverlaufs ohne relative Verschiebung. b/c) konstante Verschiebung nach kurvenaußen/kurveninnen. d) Sicherheitslinie, spitzes Fahren der Kurven mit möglichst kleinem Kurvenradius am Scheitelpunkt. e/f) nichtlineare Verschiebung nach kurvenaußen. g) Rennlinie, starkes schneiden der Kurve. h,i) nichtlineare Verschiebung nach kurveninnen .....	96
Abbildung 5-15: Logik zur Klassifikation der gefahrenen Trajektorie, dargestellt als Entscheidungsbaum .....	98
Abbildung 5-16: Verteilung der Linienwahl nach Klassifikation des Verlaufs der Querablage gruppiert nach Fahrerfahrung. Die Fehlerbalken geben die obere und untere Grenze der Gruppeninternen Schwankungen bei Fahrerindividuellen Auswertung an .....	99

Abbildung 5-17: Verteilung der Kennwerte zur Auswertung der nicht modellhaft erklärbaren Positionsvariation während stationärer Kurvenfahrt .....	101
Abbildung 5-18: Verteilung der geglätteten kontinuierlichen Positionsverschiebung in Richtung Kurvenmitte ( $KLW, \Delta Pos, in$ ) oder Kurvenaußenseite ( $KLW, \Delta Pos, au$ ) während stationärer Kurvenfahrt .....	102
Abbildung 6-1: Fehlerfreie (links) und fehlerbehaftete (rechts) Einlenkvorgänge unterschiedlicher Kurvenfahrten (farbig kodiert) .....	105
Abbildung 6-2: Kumulierte Häufigkeit der Bewertung von Einlenkvorgängen mit Frequenzkennwert.....	108
Abbildung 6-3: Verteilung der Kennwerte zur Bewertung dynamischer Einlenkvorgänge .....	112
Abbildung 6-4: Verteilung der Kennwerte zur Bewertung dynamischer Einlenkvorgänge bei zusätzlicher Normierung der Kennwerte auf die Rollwinkeländerung während des Einlenkvorgangs .....	113
Abbildung 7-1: Streudiagramme der Indikatoren zur Bewertung der stationären Kurvenfahrt anhand der Rollbewegung. Als Indikatoren sind die Medianwerte zufällig gezogener Kennwert- verteilungen genutzt. Links- und Rechtskurven sind als separate Stichproben behandelt. Pro Fahrer und Kurvenrichtung sind $W=100$ Stichproben vom Umfang $N=100$ dargestellt .....	122
Abbildung 7-2: Fünfstufiges Modell zur Identifikation der Fahrfertigkeiten anhand der Rollbewegung in stationärer Kurvenfahrt.....	123
Abbildung 7-3: Streudiagramme der Indikatoren zur Fahrfertigkeitsbestimmung anhand der Fahrfehlerdetektion. Als Indikator ist die relative Häufigkeit von Kurvenfahrten mit einer Bewertung von $KF, i > 0,2$ verwendet. Links- und Rechtskurven sind als separate Stichproben behandelt .....	124
Abbildung 7-4: Dreistufiges Modell zur Bewertung der Fahrfertigkeiten anhand der Fahrfehlerdetektion.....	124
Abbildung 7-5: Streudiagramme der Indikatoren zur Fahrfertigkeitsbestimmung anhand der Linienwahl in stationäre Kurvenfahrt (rechts). Vierstufiges Modell zur Bewertung der Fahrfertigkeitsniveaus anhand der Linienwahl (links).....	125
Abbildung 7-6: Streudiagramme der Indikatoren zur Fahrfertigkeitsbestimmung während des Einlenkvorgangs. Als Indikatoren sind die 70. Perzentile zufällig gezogener Verteilungen der Kennwerte verwendet. Links- und Rechtskurven sind als separate Stichproben behandelt. Pro Fahrer und Kurvenrichtung sind $W=100$ Stichproben vom Umfang $N=100$ dargestellt .....	127
Abbildung 7-7: Dreistufiges Modell zur Bewertung der Fahrfertigkeiten anhand der Kennwerte des Einlenkvorgangs .....	127
Abbildung 7-8: Zuordnung der Fahrfertigkeitsniveaus auf Basis der vier Kriterien für Links- und Rechtskurven .....	128
Abbildung 7-9: Stichprobenumfang zur Klassifikation der Fahrfertigkeiten anhand der Kennwerte der Rollbewegung ohne Information zur Rollwinkelverteilung .....	130
Abbildung 7-10 Stichprobenumfang zur Klassifikation der Fahrfertigkeiten anhand der Kennwerte der Rollbewegung und der Rollwinkelverteilung .....	131
Abbildung 7-11: Gegenüberstellung der Klassifikationsgüte für unterschiedliche Zuordnung der Stichproben zu Fahrfertigkeitsniveaus.....	132
Abbildung 7-12: Konsistenz der Stichprobengruppierung in Abhängigkeit der Clusteranzahl und des Stichprobenumfangs am Beispiel der Rollbewegungsindikatoren .....	133
Abbildung 7-13 Stichprobenumfang zur Klassifikation der Fahrfertigkeiten anhand von Fahrfehlerkorrekturen (FK) und den Kennwerten des Trajektorienverlaufs (LW) .....	134
Abbildung 7-14 Stichprobenumfang zur Klassifikation der Fahrfertigkeiten anhand des Einlenkvorgangs .....	135

---

Abbildung 7-15: Konsistenz der Stichprobengruppierung in Abhängigkeit der Clusteranzahl und des Stichprobenumfangs für den Einlenkvorgang .....	136
Abbildung A-1: Versuchsmotorrad inkl. Messtechnikaufbau .....	142
Abbildung A-2: Exemplarische Synchronisierung der Rollraten aus Inertialmesseinheit (blau) und Kamerabildern (rot und gelb) .....	143
Abbildung A-3 Entscheidungsbaum für die Zuordnung der identifizierten Fahrstreifencluster zu den Fahrstreifenmarkierungen Rechts (R), Mitte (M) und Links (L) .....	144
Abbildung A-4: Häufigkeitsverteilung der Distanzmaße für das initiale Clustering basierend auf dem geschätzten Fahrstreifenverlauf (blau) sowie des Clustering basierend auf der Approximation des Clusters mit der größten Anzahl an zugeordneten Fahrstreifenmarkierungen (rot). Verteilung zugehörig zu Abbildung 3-4 .....	145
Abbildung A-5: Häufigkeitsverteilung der Entfernung des Fahrzeugs zur rechten Fahrstreifenmarkierung .....	145
Abbildung B-1: Gerichteter Multigraph der Zerlegung in Manöver-Primitive .....	147
Abbildung B-2: Häufigkeitsverteilung der Segmentierungspunkte über der Rollrate für den annotierten Messdatensatz zum Training und Validierung der Segmentierungsmodelle .....	147
Abbildung B-3: Struktur der HHMM Zustandsübergangsmatrix A .....	148
Abbildung B-4: Pseudo-Code der Plausibilisierung der Manöver-Sequenz Abfolge zur Vermeidung fehlerhafter Klassifikation des Ein- und Auslenkvorgangs als Richtungswechsel .....	148
Abbildung C-1: Impulsantwort des Bandpassfilters zur Filterung der Rollwinkel und Rollrate stationärer Kurvenfahrt .....	151
Abbildung C-2: Impulsantwort des Bandpassfilters zur Filterung der Rollrate beim Einlenkvorgang. Die Grenzfrequenzen sind auf die Trennung von Fahrern unterschiedlicher Fahrerfahrung optimiert .....	151
Abbildung C-3: Streudiagramme der Kennwerte für die Rollbewegung in stationärer Kurvenfahrt und möglichen Einflussfaktoren vor Skalierung und Normierung ..	152
Abbildung C-4: Ergebnisse der Frequenzoptimierung der unteren (HP) und oberen (TP) Grenzfrequenz des Bandpassfilters zur Erkennung fehlerhafter Einlenkvorgänge mittels t-Test Statistik .....	157
Abbildung C-5: Verteilung der Kennwerte zur Bewertung dynamischer Aufrichtvorgänge beim Verlassen der Kurvenfahrt .....	158
Abbildung C-6: Fahrerindividuelle Kennwertverteilungen der Bewertung der Rollbewegung in stationärer Kurvenfahrt. Links- und Rechtskurven sind als separate Verteilungen dargestellt .....	159
Abbildung C-7 Fahrerindividuelle Kennwertverteilungen der Bewertung stationärer Kurvenfahrt anhand der Fahrfehlerdetektion. Links- und Rechtskurven sind als separate Verteilungen dargestellt .....	160
Abbildung C-8: Fahrerindividuelle Kennwertverteilungen zur Bewertung der stationären Kurvenfahrt anhand der Linienwahl. Links- und Rechtskurven sind als separate Verteilungen dargestellt .....	160
Abbildung C-9: Fahrerindividuelle Kennwertverteilungen der Bewertung des Einlenkvorgangs in Kurvenfahrt. Links- und Rechtskurven sind als separate Verteilungen dargestellt .....	161
Abbildung C-10: Fahrerindividuelle Rollwinkelverteilung. Links- und Rechtskurven sind als separate Verteilungen dargestellt .....	162
Abbildung C-11: Dreistufiges Fahrfertigkeitsmodell für die stationäre Kurvenfahrt. Abgeleitet aus den Kennwertverteilungen der Rollbewegung sowie den Informationen der Probandenstudie .....	162

Tabelle 3-1: Genauigkeit der 3D-Orientierung der IMU MTi-G-700 .....	22
Tabelle 3-2: Probandenbewertung und -einteilung .....	36
Tabelle 4-1: Parameter der Kurvenfahrten in Abbildung 4-1 .....	38
Tabelle 4-2: Varianten zur Untersuchung der Beobachtungsgrößen.....	60
Tabelle 4-3: Absolute Label-Konformität für das HHMM-Segmentierungsverfahren.....	61
Tabelle 4-4: Varianten zur Untersuchung des Einfluss der Signalglättung.....	62
Tabelle 4-5: Klassenspezifische Sensitivität für HHMM verschiedener Varianten.....	63
Tabelle 4-6: Klassenspezifische Präzision für HHMM verschiedener Varianten .....	64
Tabelle 4-7: Absolute Label-Konformität für SHMM-Segmentierungsverfahren.....	65
Tabelle 4-8: Gegenüberstellung des klassenspezifischen <i>FI</i> -Werts auf Manöverebene...67	
Tabelle 4-9: Fahrerindividuelle Segmentierungsperformance für HHMM-Verfahren mit Modellvariante Var4.1 .....	68
Tabelle 5-1: Ordinalskala Annotation Testdatensatz.....	74
Tabelle 5-2: Korrelationsmatrix von Einflussgrößen und Kennwerten vor Korrektur und Normierung.....	83
Tabelle 5-3: Merkmale zur Klassifikation eines Handlungsverbunds.....	89
Tabelle 5-4: Übersicht der Regressionsmodelle zur Trajektorien Approximation.....	97
Tabelle 7-1: Indikatoren und Stichprobenzuordnung der untersuchten Klassifikatorvarianten (1) .....	130
Tabelle 7-2: Indikatoren und Stichprobenzuordnung der untersuchten Klassifikatorvarianten (2) .....	135
Tabelle 7-3: Indikatoren und Stichprobenzuordnung der untersuchten Klassifikatorvarianten (3) .....	136
Tabelle A-1: Technische Daten des Versuchsfahrzeugs .....	142
Tabelle B-1: Auflistung definierter Manöver-Primitive.....	146
Tabelle B-2: Konfusionsmatrix HHMM Variante 1 .....	149
Tabelle B-3: Konfusionsmatrix HHMM Variante 4.1 .....	149
Tabelle B-4: Konfusionsmatrix HHMM Variante 4.2.....	150
Tabelle B-5: Klassenspezifische Kennwerte für SHMM $\varphi = 1^\circ$ .....	150
Tabelle C-1: Parameter zur Normierung der Kennwerte der Rollbewegung in stationärer Kurvenfahrt.....	153
Tabelle C-2: Korrelationsmatrix der Kennwerte der Rollbewegung in stationärer Kurvenfahrt nach erfolgter Normierung .....	153
Tabelle C-3: Parameter zur Normierung der Kennwerte der Rollbewegung für Segmente mit dynamischer Rollbewegung (Einlenken, Richtungswechsel und Verlassen der Kurvenfahrt).....	153
Tabelle C-4: Ergebnisse des t-Test zur Untersuchung von Mittelwert Unterschieden der Kennwertverteilungen der Rollbewegung in stationärer Kurvenfahrt links .....	154
Tabelle C-5: Ergebnisse des t-Test zur Untersuchung von Mittelwert Unterschieden der Kennwertverteilungen der Rollbewegung in stationärer Kurvenfahrt rechts .....	155
Tabelle C-6: Ergebnisse des Kolmogorov-Smirnov-Test der Kennwertverteilungen von Fahrfehlerkorrekturen in stationäre Kurvenfahrt links .....	156
Tabelle C-7: Ergebnisse des Kolmogorov-Smirnov-Test der Kennwertverteilungen von Fahrfehlerkorrekturen in stationäre Kurvenfahrt rechts .....	156

---

# Kurzzusammenfassung

Aktuelle Unfallstatistiken zeigen, dass der Großteil der Alleinunfälle von Motorradfahrern in Kurvenfahrt stattfindet. Diese Unfälle gehen häufig auf die situative Fehleinschätzung sowie die Überschätzung der eigenen Fahrfertigkeiten zurück. Bisher wird davon ausgegangen, dass diese Art von Unfällen durch präventive Maßnahmen, wie gezieltes Fahrertraining und -sensibilisierung, sowie Assistenzsysteme in ihrer Anzahl reduzierbar sind. Für genannte Assistenzsysteme, u.a. auch ein Online Fahrertraining, ist es notwendig, das individuelle Fahrverhalten aber auch die Fahrfertigkeiten korrekt zu identifizieren. Während Modelle zur Beschreibung des allgemeinen Fahrverhaltens, z.B. in welche Rollwinkel- und Beschleunigungsbereiche der Fahrer vorgedrungen ist, bereits zahlreich untersucht wurden, ist unbekannt, woran Fahrfertigkeiten wissenschaftlich fundiert festzumachen sind und wie diese im Fahrbetrieb ermittelt werden können.

Gegenstand dieser Arbeit ist die Untersuchung, ob und mit welchen Methoden die Fahrfertigkeiten von individuellen Motorradfahrern im Straßenverkehr anhand von Kurvenfahrten messbar sind. Das beinhaltet die Analyse, welche Differenzierung im Kontext der vielfältigen Situationen möglich ist, sowie den dazu benötigten Datenumfang. Ziel des ersten Abschnitts der Arbeit ist die Klärung, in welche Teile die Kurvenfahrt zerlegt werden muss um in einem zweiten Schritt fahrfertigkeitsrelevante Merkmale und Kennwerte aus den Sequenzen extrahieren zu können. Basierend auf Fahrverhaltensmodellen und den Erkenntnissen aus der Voruntersuchung von Kurvenfahrten zweier Referenzfahrer, mit sehr hoch und sehr niedrig bewerteten Fahrfertigkeiten, ist ein Modell abgeleitet, welches das Fahrmanöver Kurvenfahrt in vier unterschiedliche Phasen zerlegt. Jede dieser Phasen entspricht einer bestimmten Handlung oder Regelstrategie, die zur Bewältigung des Fahrmanövers notwendig ist und anhand deren Ausführungsqualität die Fahrfertigkeiten beurteilbar sind. Zur automatischen Segmentierung und Klassifizierung der Messdaten sind zwei Algorithmen implementiert und die Performance für verschiedene Varianten evaluiert. Die Analyse der Ergebnisse zeigt, dass die Zerlegung gemäß dem gewünschten Modell dargestellt werden kann.

Der zweite Teil der Arbeit widmet sich der näheren Untersuchung von Methoden, Modellen, und Messgrößen mittels derer die Güte, d.h. die Qualität, einzelner Sequenzen quantifiziert werden kann. Zur Entwicklung und Validierung dieser Verfahren wurde eine Probandenstudie mit 19 Fahrern unterschiedlicher gesamtheitlicher Fahrerfahrung auf einer motorradtypischen Versuchsstrecke im öffentlichen Straßenverkehr durchgeführt. Die Fahrer wurden anhand des subjektiven Eindrucks und der angegebenen Erfahrung in vier Gruppen auf einer Ordinalskala eingeteilt.

Bei der Auswertung der entwickelten Methoden wird beobachtet, dass die statistische Verteilung der Beurteilungen der Sequenzen, anhand der Rollbewegung und der Positionsänderung, mit der Referenzgruppierung korreliert. Da bei der Untersuchung der Kennwerte ferner gezeigt werden kann, dass fehlerbehaftete von fehlerfreien Kurvenfahrten unterscheidbar sind, wird daraus abgeleitet, dass mit den vorgeschlagenen Methoden die Qualität eines Handlungsablaufs und damit auch die Fahrfertigkeit messbar ist. Die anfängliche Hypothese, dass die Fahrfertigkeiten mithilfe einzelner Kurvenfahrten identifiziert werden können, in der Fahrer mit hoher Fahrexpertise völlig unterschiedliche Merkmale zu Fahranfänger aufweisen, bestätigt sich indes nicht.

Bei der vertiefenden Untersuchung der fahrerindividuellen Stichproben wird gezeigt, dass eine fahrerspezifische Klassifikation des Fahrfertigkeitsniveaus mittels statistischer Indikatoren der Sequenzbewertungen möglich ist. Die Anzahl der differenzierbaren Level ist dabei abhängig von der Menge der zu Verfügung stehenden Sequenzen der einzelnen Phasen der Kurvenfahrt. So ist die Bewertung der Fahrfertigkeiten anhand der Rollbewegungsmerkmale in stationärer Kurvenfahrt aus statistischer Perspektive in fünf Kategorien möglich, während für den Fall des Einlenkens in die Kurve nur drei Level identifizierbar sind. Eine weitere Erkenntnis ist, dass das Fahrfertigkeitsniveau eines Fahrers in verschiedenen Situationen, wie beispielsweise Links- oder Rechtskurven oder verschiedenen Phasen der Kurvenfahrt, unterschiedlich stark ausgeprägt sein kann und dies mit dem Verfahren messbar ist.

In Summe legt die in dieser Arbeit erarbeitete Methode den Grundstein für eine im realen Fahrbetrieb stattfindende Identifikation der Fahrfertigkeiten. Die Erkenntnisse können als Ausgangsbasis für die Entwicklung einer Reihe möglicher fahreradaptiver Assistenzsysteme zur Verbesserung der Motorradsicherheit herangezogen werden.

# 1 Motivation

Gemäß den Daten des Statistischen Bundesamtes sind Fahrer von motorisierten Zweirädern mit amtlichen Kennzeichen<sup>1</sup> im Straßenverkehr besonders gefährdet, in einen tödlichen Unfall verwickelt zu werden. Das Risiko, tödlich auf einem Motorrad zu verunglücken, ist dabei bezogen auf die Fahrleistung etwa 19-fach so hoch wie in einem Pkw zu sterben.<sup>2</sup> Die jährliche Unfallstatistik von 2016 zeigt dabei, dass 29 % aller polizeilich aufgenommenen Unfälle, Alleinunfälle waren, d.h. ohne Einwirkung oder Zutun eines Unfallgegners zustande kamen<sup>3</sup>. Diese Unfälle sind größtenteils auf Fehlverhalten und Fahrfehler des Motorradfahrers zurückzuführen und damit auf einen Mangel oder ein Überschätzen der eigenen Fahrfertigkeiten. Folgt man der Analyse von Liers et al., die auf den Daten der GIDAS Datenbank von 1999-2011 beruht, so treten 70 % der Unfälle in Kurvenszenarien auf<sup>4</sup>, was ebenfalls durch Zahlen der Unfallforscher der GDV aus dem Jahr 2017 gestützt wird, siehe Abbildung 1-1.




Abbildung 1-1: Lokalisierung und Kategorisierung von Alleinunfälle<sup>4,5</sup>

Ein Sturz auf der Fahrbahn ist typischerweise die Folge mangelnder Kontrolle, d.h. dem Überschätzen des ausnutzbaren Kraftschlusspotentials, welches auch durch Verunreinigung oder Nässe herabgesetzt sein kann. Das Verlassen der Fahrbahn tritt hauptsächlich bei nicht angepasster Geschwindigkeit beim Einleiten einer Kurvenfahrt oder sich innerhalb der Kurvenfahrt vergrößernden Kurvenkrümmung auf.<sup>5</sup>

<sup>1</sup> Erforderlich für Fahrzeuge mit min. 125 ccm Hubraum. Motorroller, sind in der Statistik nicht enthalten.

<sup>2</sup> Destatis: Verkehrsunfälle Zeitreihen (2017). Abschnitt 5.2.2 S. 136 & Abschnitt 7.4 S. 203.

<sup>3</sup> Destatis: Verkehr Verkehrsunfälle 2016 (2017). Abschnitt 3.1 S. 99ff.

<sup>4</sup> Liers, H. et al.: Analysis of PTW Accidents in GIDAS (2014), S. 109.

<sup>5</sup> GDV: Verbesserung der Motorradsicherheit (2017), S. 5–6.



## **Fahrfertigkeitsmodell für adaptive Assistenzsysteme**

Um die Ziele der Europäischen Kommission als auch des Bundesministeriums für Verkehr und digitale Infrastruktur (BMVI) zu erreichen, die Zahl der Verkehrstoten um 50 %<sup>6</sup>, respektive 40 %<sup>7</sup>, gegenüber 2010 bis zum Jahre 2020 zu reduzieren, sind eine Reihe von Maßnahmen beschlossen und bereits umgesetzt worden. Um die thematisierten Alleinunfälle Kurvenfahrt zu reduzieren, werden von der GDV als auch dem von der Europäischen Kommission geförderten Forschungsprojekt SAFERIDER<sup>8</sup> fortgeschrittene Assistenzsysteme wie ein adaptives Kurvenwarnsystem untersucht und empfohlen<sup>9</sup>. Die Unfallforschung der Versicherer kommt dabei zu dem Ergebnis, dass eine Kurvenwarnfunktion in 59% der untersuchten Unfälle einen positiven Einfluss auf das Unfallgeschehen haben könnte<sup>10</sup>.

Für die technische Umsetzung solcher Assistenzsysteme stellt sich besonders die Frage nach einem geeigneten Modell zur Beschreibung des Fahrers, um die Warnungen nicht nur adaptiv auf die Situation, sondern auch adaptiv auf die Fahrerbedürfnisse auslegen zu können. Ein sehr erfahrener und versierter Fahrer benötigt beispielsweise nicht in den gleichen Situationen eine Warnung wie ein Fahranfänger. Für eine größtmögliche Wirksamkeit und Akzeptanz des Systems sollte das Fahrermodell die individuellen Grenzen des Fahrers in seinem aktuellen Leistungszustand für die unterschiedlichsten Szenarien abdecken.

Wie und insbesondere in welcher Abstufung das Fahrfertigkeitsniveau eines Fahrers für die Kurvenfahrt im Realverkehr gemessen werden kann, ist aus wissenschaftlicher Sicht für Motorradfahrern zum aktuellen Zeitpunkt nur unzureichend untersucht. Ist eine makroskopische Zuordnung des Fahrfertigkeitsniveaus zu einem Fahrer möglich oder können gar fahrerindividuelle Unterschiede für einzelne Situationen gemessen werden, z.B. ob Linkskurven besser oder schlechter gefahren werden als Rechtskurven? Es ist unklar, welche Fertigkeiten für die Kurvenfahrt messbar sind und wie diese ggf. auch über die unterschiedlichsten im Realverkehr auftretenden Situationen schwanken. Sind die Messunsicherheiten klein genug, um Unterschiede festzustellen?

---

<sup>6</sup> European Commission: Towards European road safety (2010), S. 4.

<sup>7</sup> BMVI: Verkehrssicherheitsprogramm 2011-2020 (2015), S. 3.

<sup>8</sup> <http://www.saferider-eu.org/>

<sup>9</sup> Borin, A.: SAFERIDER (2012), S. 1–2.

<sup>10</sup> GDV: Verbesserung der Motorradsicherheit (2017), S. 10.

## **Fahrertraining durch Online Feedback**

Die Messung und Identifikation von Fahrerfertigkeiten im Realverkehr kann auch anhand eines zweiten Anwendungsgebiets motiviert werden, dem Training des Motorradfahrers durch kontinuierliches Feedback. Ziel ist es, die Fertigkeiten der Fahrzeugbeherrschung und das Risikobewusstsein bzw. die Risikovermeidung zu verbessern. De Craen et al. konnten bereits einen Langzeiteffekt nach nur einem eintägigen Risikotraining, dass sich aus Theorie und Praxisteil zusammensetzte, nachweisen.<sup>11</sup> Der tatsächliche Nutzen eines Fahrertrainings hängt jedoch immer von den Zielen, Trainingsinhalten und Rahmenbedingungen ab. Ein Review von Studien zur Effektivität von Fahrertrainings kommt zu keinen eindeutigen Ergebnissen hinsichtlich der Risikoverminderung oder Fertigungsverbesserung.<sup>12</sup> Dies könnte auch auf den grundsätzlichen Nachteil vom heutigen Fahrertraining zurückzuführen sein, da es sich meist über einen kurzen Zeitraum erstreckt, unregelmäßig wiederholt wird und in einem abgeschlossenen, sicheren Testumfeld stattfindet.

Die zunehmende Verfügbarkeit von Sensoren im Motorrad ermöglicht es, die Nachteile des zeitlich begrenzten und abgeschlossenen Trainings zu beseitigen. Heutige bereits im Markt befindliche Systeme geben dem Fahrer beispielsweise ein visuelles Feedback über die maximal erzielte Schräglage. Der Nutzen hinsichtlich des Fahrertrainings fällt aufgrund des gewählten Maßes (Maximum des Rollwinkels in einem bestimmten Zeitintervall) jedoch gering aus. Aus Sicherheitsaspekten ist es ebenfalls fragwürdig, wenn es den Fahrer dazu verleitet über seine Grenzen blind hinaus zu gehen.

Ein denkbarer Ansatz ist es, die Fahrdynamikdaten hinsichtlich fehlerhafter oder unerwünschter Verhaltensmuster auszuwerten, die Ergebnisse mit einem für die Fahrerfertigkeiten des Fahrers passenden Modell zu vergleichen und ihm anschließend ein detailliertes und verständliches Feedback zu geben, mit dem er sein Verhalten anpassen kann. Der Schlüssel zu einem solchen elektronischen Fahrtrainer ist einerseits ein Modell zur Detektion von verschiedenen Fahrfehlern oder falschen Verhaltensweisen anhand geeigneter Metriken. Zum anderen ist auch für den Abgleich mit dem typischen Fahrverhalten ein Modell des Fahrers notwendig.

Wie im vorangegangenen Abschnitt beschrieben mangelt es an Metriken zur Beschreibung einer guten bzw. fehlerhaften Kurvenfahrt sowie der Analyse, ob diese Metriken aussagekräftig, d.h. reproduzierbar sind und eine Differenzierung der Fahrmanöver Performance zulassen.

---

<sup>11</sup> Vgl. Craen, S. de et al.: Effects of advanced rider training (2014).

<sup>12</sup> Vgl. Daniello, A. et al.: Effectiveness of Motorcycle Training and Licensing (2009).

## **1.1 Aufbau der Arbeit**

Im folgenden Abschnitt werden Grundlagen zur Kurvenfahrt eines Einspurfahrzeugs vermittelt und eine Übersicht zum Stand der Forschung im Bereich Fahrermodellierung und -bewertung vorgestellt. Die Zusammenstellung beinhaltet neben der begrenzten Zahl von Fahrermodellen für Motorradfahrer auch die von Pkw-Fahrern.

Aufbauend auf dem Stand der Forschung werden Forschungsfragen zur Modellierung von Motorradfahrern und deren Fahrfertigkeiten und Fahrfehlern in Kurvenfahrten formuliert.

In dem darauffolgenden Kapitel 3 wird ein Überblick über die Untersuchungswerkzeuge und die angewendeten Methoden und Verfahren zur Datenaufbereitung, die im Rahmen der Arbeit verwendet werden, gegeben. Dies umfasst das Fahrzeug und die verwendete Messtechnik inkl. des Verfahrens zur Bestimmung der lateralen Fahrzeugposition innerhalb des Fahrstreifens. Ebenfalls wird auf die Probandenstudie eingegangen, welche die Ausgangsbasis für die Entwicklung und Validierung der Methoden zur Bewertung der Fahrfertigkeiten bildet, eingegangen.

In den nachfolgenden Kapiteln werden die entwickelten Methoden und Verfahren, die zur Bewertung der Kurvenfahrt notwendig sind, detailliert dargelegt und analysiert. Dies umfasst in Kapitel 4 das Verfahren zur Segmentierung der Kurvenfahrt in kleinere, generalisierte Sequenzen, die Handlungsabläufe und Regelstrategien zur Bewältigung des Fahrmanövers repräsentieren. Sowohl die Modellstruktur als auch die Eingangsgrößen für ein Modell zur automatischen Segmentieren werden detailliert analysiert und abschließend mit dem Stand der Technik verglichen.

In den anschließenden Kapitel 5 und 6 wird auf die verwendeten Verfahren zur Extraktion von Kennwerten und Fahrfertigkeitsindikatoren aus den Sequenzen der aus Kapitel 4 hervorgehenden Kurvenzerlegung eingegangen. In Kapitel 5 ist der Fokus auf die stationäre Kurvenfahrt gelegt, während sich Kapitel 6 mit der Bewertung der Kurveneinleitung und des Verlassens beschäftigt. Beide Abschnitte haben gemeinsam, dass klassische regressions- und filterbasierte Verfahren, welche auf Hypothesen zum idealen Signalverlaufs der betrachteten Messgröße beruhen, eingesetzt werden.

In Kapitel 7 werden die unterschiedlichen Verfahren bezüglich der Identifikation der individuellen Fahrfertigkeiten des Probandenkollektives untersucht und bewertet. Es wird sowohl die grundsätzlich realisierbare Abstufung der einzelnen Fahrer, als auch die Zuverlässigkeit bzw. die notwendige Datengrundlage analysiert und diskutiert.

Die Arbeit schließt mit einem Fazit und einer Diskussion zu den aufgestellten Forschungsfragen sowie dem Ausblick auf weitere erforderliche Untersuchungen ab.

---

## 2 Stand der Forschung und Technik

Vor dem Einstieg in den Stand der Forschung wird im ersten Abschnitt dieses Kapitels auf die Grundlagen der Motorraddynamik eingegangen sowie die Begriffsdefinition von Fahrfertigkeit, die zum Verständnis des weiteren Kapitels notwendig sind. Der darauffolgende Abschnitt behandelt vorhandene Modelle zur Charakterisierung des Fahrstiles und Fahrexpertise des Fahrers. Die Recherche wird aufgrund des begrenzten Stands der Technik für Motorradfahrer-spezifische Modelle auf Pkw-Fahrermodelle ausgeweitet. Aus dem Stand der Forschung werden in Abschnitt 2.3 abschließend offene Forschungsfragen abgeleitet, die im Rahmen dieser Arbeit beantwortet werden sollen.

### 2.1 Grundlagen

#### 2.1.1 Koordinatensysteme

Im Rahmen der Arbeit werden die in Abbildung 2-1 gezeigten und im Folgenden definierten Koordinatensysteme<sup>13</sup> verwendet:

- Motorradfestes Koordinatensystem<sup>14</sup>, gekennzeichnet ohne Index. Dieses kartesische Koordinatensystem ist so definiert, dass der Ursprung im Schwerpunkt des Fahrzeugs liegt. Die x-Achse zeigt dabei in Fahrzeugrichtung nach vorne, die y-Achse senkrecht dazu nach links und die z-Achse senkrecht zu der x-y-Ebene nach oben. Das Koordinatensystem folgt allen Bewegungen des Fahrzeugs. In diesem System werden die Drehraten und Beschleunigungen angegeben.
- Lokales Erdfestes Koordinatensystem<sup>15</sup>, das mit dem Index „e“ versehen ist. Der Ursprung dieses Koordinatensystems liegt ebenfalls im Schwerpunkt des Fahrzeugs. Die  $x_e$ -Achse ist in Richtung geographischen Ostens ausgerichtet, die  $y_e$ -Achse in Richtung Norden und die  $z_e$ -Achse senkrecht dazu nach oben.

---

<sup>13</sup> Vgl. DIN ISO 8855:2013-11 Straßenfahrzeuge - Begriffe (2013).

<sup>14</sup> Entspricht dem Fahrzeugfesten Koordinatensystem der ISO Norm.

<sup>15</sup> Entspricht in dieser Definition dem ENU Navigationskoordinatensystem.

- Horizontiertes Motorrad-Koordinatensystem, mit Index „hor“ versehen. Der Ursprung dieses Koordinatensystems liegt im Schwerpunkt des Fahrzeugs. Die Richtung der  $x_{\text{hor}}$ -Achse und  $y_{\text{hor}}$ -Achse ist durch die Projektion der  $x$ - bzw.  $y$ -Achse des Motorradfesten Koordinatensystems in die  $x_e$ - $y_e$ -Ebene definiert. Die  $z_{\text{hor}}$ -Achse ergänzt das Rechtssystem und zeigt nach oben. Die Orientierung des Fahrzeugs im Raum wird im Horizontierten Koordinatensystem angegeben.
- Horizontiertes Vorderrad-Koordinatensystem, welches mit dem Index „vh“ gekennzeichnet ist. Die  $x_{\text{vh}}$ - und  $y_{\text{vh}}$ -Achse des Koordinatensystems liegen in der Fahrbahnebene. Die Richtung der  $x_{\text{vh}}$ -Achse und  $y_{\text{vh}}$ -Achse ist durch die Projektion der  $x$ - und  $y$ -Achse des Motorradfesten Systems auf die Fahrbahnebene definiert. Die  $z_{\text{vh}}$ -Achse zeigt senkrecht zur Fahrbahnebene nach oben. Der Ursprung des Koordinatensystems liegt im Kontaktpunkt von Vorderrad und Fahrbahn. Das Horizontierte Vorderrad-Koordinatensystem wird zur Angabe der lateralen Position des Fahrzeugs im Fahrstreifen genutzt.




Abbildung 2-1 Verwendete Koordinatensysteme und deren Orientierung zueinander, eigene Darstellung




Abbildung 2-2: Rollgleichgewicht in stationärer Kurvenfahrt<sup>17</sup>

## 2.1.2 Kurvenfahrt von Einspurfahrzeugen

Im Gegensatz zu einem herkömmlichen Pkw kann ein Motorrad eine Kurve nur mit einem an die Querbewegung angepassten Rollwinkel befahren. Im folgenden Abschnitt wird auf die physikalischen Grundlagen hierfür eingegangen.

## Stationäre Kurvenfahrt

Die Notwendigkeit eines Rollwinkels für die stationäre Kurvenfahrt wird an Abbildung 2-2 verdeutlicht. Um eine Kurve mit konstanter Krümmung bei einer gegebenen konstanten Geschwindigkeit zu befahren, muss der Rollwinkel so vom Fahrer eingestellt sein, dass die Resultierende aus Querbesehleunigung  $a_{y,hor}$  und Erdgravitation  $g$  die Aufstandslinie der Reifen schneidet. Der notwendige geometrische Rollwinkel setzt sich aus dem physikalischen Rollwinkel  $\varphi_{th}$  und einem Reifenkontur abhängigen Zusatzrollwinkel  $\varphi'$  zusammen, wie in Abbildung 2-2 dargestellt. Der Zusatzrollwinkel liegt dabei in der Größenordnung von ca. 10 % des physikalischen Rollwinkels<sup>16</sup>. Als eine gute Näherung hat sich der Faktor 1,115<sup>17</sup> rausgestellt mit dem die Berechnung vereinfacht werden kann (siehe Formel 2.1 bis 2.3).

$$\varphi_{th} = \arctan\left(\frac{a_{y,hor}}{g}\right) \quad (2.2)$$

$$\varphi' = \arcsin\left(\frac{r_{Kontur}}{h_S - r_{Kontur}} \cdot \frac{a_{y,hor}}{\sqrt{g^2 + a_{y,hor}^2}}\right) \approx 0,115 \cdot \varphi_{th} \quad (2.3)$$

$$\varphi = \varphi_{th} + \varphi' \approx 1,115 \cdot \varphi_{th} \quad (2.1)$$

Wird das Gleichgewicht gestört, z.B. durch bewusste Lenkbewegung oder aber auch Fahrbahnunebenheiten, die die wirkenden Kräfte am Reifen beeinträchtigen, kommt es zu einer Rollbewegung um die Aufstandslinie. Mit zunehmender Geschwindigkeiten wird die Rollbewegung durch die Lenk-Roll-Kopplung und die zunehmenden Kreiselkräfte stabilisiert, typischerweise wird hier eine untere Grenzgeschwindigkeit von 30 km/h genannt<sup>18</sup>. Der Fahrer muss theoretisch nicht aktiv durch selbst aufgebraachte Lenkkräfte eingreifen. Die Stabilisierung erfolgt rein aufgrund des gyroskopischen Effekts des Vorderrads. Bei einer Rollbewegung nach rechts wird eine Lenkbewegung nach rechts initiiert. Die Lenkbewegung nach rechts bewirkt wiederum eine Rollbewegung nach links, der eine Lenkbewegung nach links folgt. Hier schließt sich der Kreis und der Effekt beginnt von vorne. Je nach Einwirkung des Fahrers auf das Lenksystem werden die Amplituden der Selbststabilisierung der Rollbewegung verstärkt oder abgeschwächt.

<sup>16</sup> Weidele, A.: Untersuchungen zum Bremsverhalten von Motorrädern unter besonderer Berücksichtigung der ABS-geregelten Kurvenbremsung (1994).

<sup>17</sup> Schröter, K. G.: Dissertation, Brake steer torque optimized corner braking motorcycles (2014).

<sup>18</sup> Schröter, K. G.: Dissertation, Brake steer torque optimized corner braking motorcycles (2014), S. 26.

## Kurven Ein- und Ausfahrt

Bei der Einfahrt in eine Kurve bzw. Ausfahrt aus einer Kurve wird ebenfalls der Effekt der Bidirektionalen Lenk-Roll-Kopplung genutzt. Entsprechend der oben beschriebenen Wirkkette muss ein nach kurvenaußen aufgebrachtes Lenkmoment, das zu einem Lenkwinkel in Richtung der Kurvenaußenseite führt, aufgebracht werden, um eine Rollbewegung zur Kurveninnenseite zu initiieren. Dieser Vorgang wird als gegenläufiger Lenkimpuls<sup>19</sup> bezeichnet. Das zur Kurveninnenseite gerichtete Rollmoment wird sowohl durch den Effekt der Kreiselkräfte als auch die Schräglaufseitenkraft, die sich mit zunehmenden Schräglauf infolge des aufgebrachten Lenkwinkel aufbaut, verursacht. Aufgrund der beim Einlenken noch fehlenden Zentripetalkraft kippt das Fahrzeug durch das Rollmoment zur Kurveninnenseite und in Folge der einwirkenden Gravitationskraft erhöht sich die Rollbewegung um die Längsachse bis der Fahrer die Bewegung durch eine Lenkbewegung nach kurveninnen stoppt und sich ein Gleichgewicht der Beschleunigungen einstellen kann.

Beim Verlassen der stationären Kurvenfahrt erfolgt der Lenkimpuls analog dazu nach kurveninnen, um das Fahrzeug nach kurvenaußen rollen zu lassen. Das Rollgleichgewicht wird durch das Lenkimpuls-induzierte Rollmoment sowie den über den Lenkwinkel verkleinerten Kurvenradius gestört, sodass das Fahrzeug beginnt sich aufzurichten.

### 2.1.3 Begriffsdefinition Fahrfertigkeit

Die Definition des Begriffs „Fahrfertigkeit“ erfolgt anhand des Modells zur zielgerichteten Tätigkeiten des Menschen nach Rasmussen. Die Bewältigung einer komplexen Aufgabe erfolgt demnach zu unterschiedlichen Teilen durch wissensbasiertes, regelbasiertes und fertigkeitsbasiertes Handeln. Dabei ist das fertigkeitsbasierte Handeln die zeitlich effektivste und am meisten automatisierte Verhaltensform. Sie wird bei routinemäßigen und wiederkehrenden Situationen genutzt, muss jedoch in einem langwierigen Lernprozess eintrainiert werden muss<sup>20</sup>.

„Fahrfertigkeit“ bezeichnet im Kontext dieser Arbeit daher die Fähigkeit, die Aufgaben der Fahrzeugführung und Fahrzeugstabilisierung im gegebenen Fahrumfeld möglichst durch fertigkeitsbasiertes Handeln vollständig automatisiert zu bewältigen. Dabei sind die Fahrferigkeiten umso höher einzuschätzen, desto weniger die Ebene des fertigkeitsbasierten Handelns verlassen wird, d.h. umso weniger regel- oder wissensbasierte Korrekturen notwendig sind.

---

<sup>19</sup> Im Englischen als „counter-steering“ bezeichnet.

<sup>20</sup> Vgl. Rasmussen, J.: Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models (1983).

## 2.2 Fahrermodellierung

Die hier vorgestellte Fahrermodellierung kann in zwei Kategorien unterteilt werden. Zum einen gibt es Modelle, die die Fahrfertigkeiten anhand der statistischen Verteilung bestimmter Kennwerte zu schätzen versuchen. Zur Schätzung der Kennwerte wird hierbei der Datensatz eines oder mehrerer Fahrzyklen herangezogen. Solche Fahrermodelle werden beispielsweise dazu genutzt, Komfortfunktionen heutiger und zukünftiger Assistenzsysteme an das Gesamtverhalten des Fahrers anzupassen. Im Rahmen dieser Arbeit werden sie als „Indirekte statistische Fahrfertigkeitsmodelle“ bezeichnet. Der Begriff „indirekt“ wurde dabei aus dem Grund gewählt, dass viele der folgenden Kennwerte keinen direkten Zusammenhang zu den in der Definition aufgeführten Kriterien aufweisen und viel mehr ein Verhalten als eine Fertigkeit beschreiben.

Die zweite Kategorie von Verfahren zur Fahrfertigkeitsmodellierung bewertet direkt die Ausführung von zuvor definierten Referenzmanövern. Der ausgegebene Kennwert lässt einen direkten Rückschluss auf die Leistung des Fahrers zu in Bezug auf die Fahrerfahrung und Beherrschung der Fahrzeugführung und –stabilisierung.

### 2.2.1 Indirekte statistische Fahrfertigkeitsmodelle

Die meisten Modelle zur Beschreibung des Fahrers basieren auf der Verteilung einfacher fahrdynamischer Messgrößen wie der Geschwindigkeit, der Längs- und Querschleunigung sowie deren zeitlicher Ableitung, dem Ruck in der entsprechenden Richtung. Auch die laterale Positionierung sowie deren Änderung innerhalb des Ego-Fahrstreifens finden sich in der Literatur. Die Statistik der entsprechenden Kenngrößen korreliert daneben, unter bestimmten Randbedingungen, mit bestimmten Verhaltenstypen und Fertigkeiten.

#### Beschleunigungsbasierte Modelle

Ein einfaches und häufig genutztes Modell zur Beschreibung des Fahrstils ist das sogenannte g-g-Diagramm.<sup>21</sup> In dieser Darstellung sind die Messwerte der Längsbeschleunigung über denen der Querschleunigung, jeweils normiert auf die Erdbeschleunigung, aufgetragen. Die physikalischen Grenzen des Diagramms sind durch den Kraftschluss zwischen der Reifen-Fahrbahn Kombination definiert. Jeder Messpunkt im Diagramm ist das Ergebnis der Fahrdynamik sowie der Fahrereingaben und dessen akzeptiertem Risiko

---

<sup>21</sup> Rice, R. S.: Measuring Car-Driver Interaction with the g-g Diagram (1973).



während des Fahrmanövers.<sup>22</sup> Somit gibt die Verteilung der Messwerte innerhalb der physikalischen Grenzen Auskunft über den Fahrstil des Fahrers. Mathematisch wird das Modell<sup>23</sup> durch folgende Gleichung beschrieben:

$$\left| \frac{a_x}{a_{x,besch,lim}} \right|^{exp} + \left| \frac{a_y}{a_{y,lim}} \right|^{exp} \leq \mu \quad \{a_x \mid a_x \geq 0\} \quad (2.1)$$

$$\left| \frac{a_x}{a_{x,brem,lim}} \right|^{exp} + \left| \frac{a_y}{a_{y,lim}} \right|^{exp} \leq \mu \quad \{a_x \mid a_x < 0\} \quad (2.2)$$

Die Variablen,  $a_{x,besch,lim}$ ,  $a_{x,brem,lim}$  bzw.  $a_{y,lim}$  bezeichnen dabei die Grenzbeschleunigungen des individuellen Fahrers. Für die Längsbeschleunigung wird der beschleunigende (positive) bzw. bremsende (negative) Fall unterschieden. Der Exponent  $e$  ermöglicht die Abhängigkeit zwischen Längs- und Querbewegung darzustellen. Bei einer linearen Abhängigkeit ( $exp = 1$ ) ergibt sich eine Raute, als einhüllende Kurve. Bei einer quadratischen Abhängigkeit ( $exp = 2$ ) entsprechend eine Ellipse.

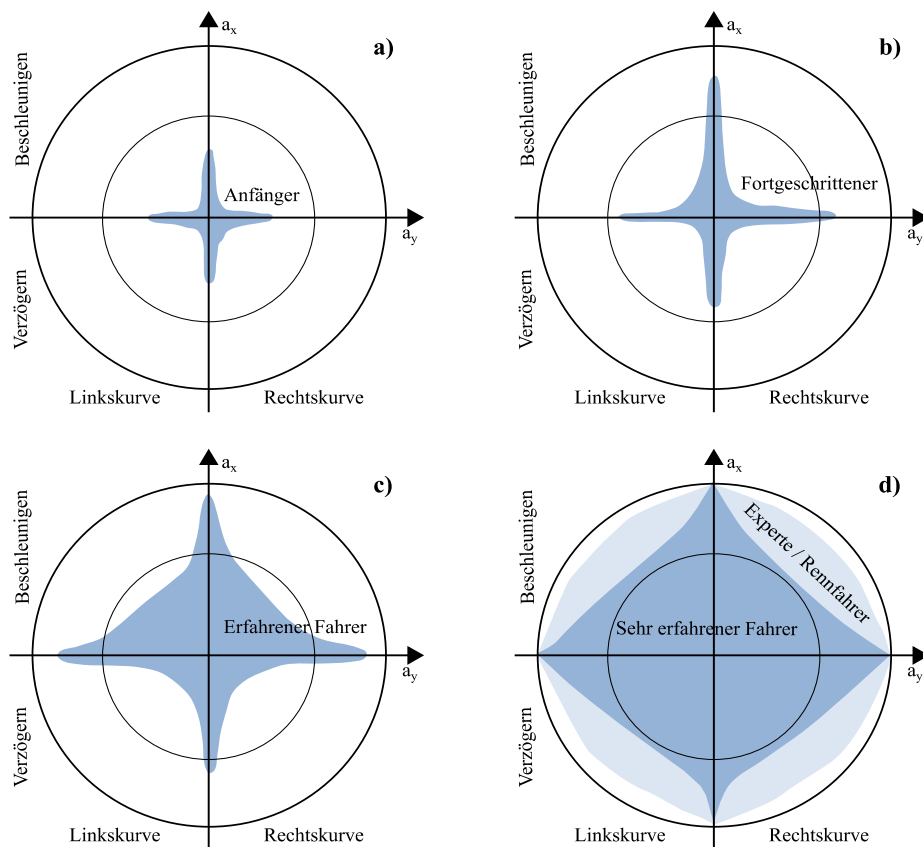


Abbildung 2-3: Fahrfertigkeitszuordnung mittels g-g-Diagramm nach Spiegel<sup>24</sup>

<sup>22</sup> Vgl. Biral, F. et al.: Combining Safety and User Preferences (2005), S. 38.

<sup>23</sup> Vgl. IPG Automotive GmbH: IPGDriver User Manual 6.5 (2015), 12, 44-46.

In der Fachliteratur finden sich bereits Zuordnungen der Modellparameter dieses Fahrstilmodells zur Fahrerfahrung bzw. Fahrexpertise<sup>24</sup>. Abbildung 2-3 veranschaulicht die von Spiegel getroffene Zuordnung verschiedener g-g-Diagramme zur Fahrexpertise.

Am oberen Ende der Skala befinden sich professionelle Rennfahrer und Experten (d), der physikalische Bereich wird bis auf wenige Randbereiche, bei der gleichzeitig hohe Längs- und Querschleunigungen wirken, ausgeschöpft.<sup>25,26</sup> Darunter definiert Spiegel aufgrund der Form und Größe der einhüllenden Fläche drei Fahrerklassen: sehr erfahrene Fahrer (ebenfalls d), erfahrende Fahrer (c), fortgeschrittene Fahrer (b) sowie Fahranfänger (a).<sup>27</sup>

In weiteren Varianten ist das Modell um die Dimension der Geschwindigkeit erweitert. Die Verteilung der Beschleunigungen wird für verschiedene diskrete Geschwindigkeitsintervalle separat modelliert, da in den unteren und oberen Intervallen eine Abnahme der erzielten Querschleunigungen beobachtet wird.<sup>28,29,30, 31</sup> Die im unteren Geschwindigkeitsbereich festgestellte Reduktion der Querschleunigung ist auf den proportionalen Zusammenhang zwischen Querschleunigung und dem Quadrat der Geschwindigkeit zurückzuführen. Es wurde festgestellt, dass dieser für alle Fahrertypen gilt. Im höheren Geschwindigkeitsbereich hingegen steigt das Risikoempfinden der Fahrer zunehmend überproportional an. Bei einer als konstant angenommenen maximal tolerierten Risikobereitschaft können damit nur noch geringere Querschleunigungen im verbleibenden Risiko bis zum Erreichen des Maximum aufgebaut werden.<sup>32</sup>

## Ruckbasierte Modelle

Der Ruck (engl. *Jerk*) ist physikalisch definiert als die zeitliche Ableitung der Beschleunigung. Er beschreibt damit den Auf- und Abbau des erzielten Beschleunigungsverhaltens. Murphey et al. klassifizieren den Fahrstil basierend auf dem in Formel 2.3 definierten Längsruck-Features  $\gamma$  in ruhig, normal und aggressiv.

---

<sup>24</sup> Vgl. Spiegel, B.: Die obere Hälfte des Motorrads (2009), S. 131.

<sup>25</sup> Vgl. Biral, F. et al.: Combining Safety and User Preferences (2005), S. 39.

<sup>26</sup> Vgl. Biral, F.; Lot, R.: An interpretative model of g-g diagrams of racing motorcycle (2009), S. 2.

<sup>27</sup> Vgl. Spiegel, B.: Die obere Hälfte des Motorrads (2009), S. 131.

<sup>28</sup> Biral, F. et al.: Combining Safety and User Preferences (2005).

<sup>29</sup> IPG Automotive GmbH: IPGDriver User Manual 6.5 (2015).

<sup>30</sup> Bosetti, P. et al.: On the human control of vehicles (2014), S. 165–166.

<sup>31</sup> Vgl. Bossdorf-Zimmer, J. et al.: Fingerprint des Fahrers (2011), S. 228.

<sup>32</sup> Vgl. Biral, F. et al.: Combining Safety and User Preferences (2005), S. 41.

$$\gamma = \frac{\sigma(J_{\text{Fen}})}{\overline{J_{\text{Ref}}}} \quad (2.3)$$

Dabei ist  $\sigma(J_{\text{Fen}})$  definiert als Standardabweichung des Rucks  $J$  im entsprechenden zeitlichen Fenster. Bezogen wird diese Größe auf einen mittleren Referenz-Ruck  $\overline{J_{\text{Ref}}}$  für den aktuellen Straßentyp.<sup>33</sup>

Modelle, die den Ruck in Fahrzeug-Querrichtung zur Fahrstilbeschreibung nutzen, sind nicht bekannt. Ein Grund hierfür könnte darin liegen, dass der Quer-Ruck für Mehrspurfahrzeuge im Wesentlichen durch die Straßengeometrie vorgegeben ist.<sup>34</sup>

### Positionsbasierte Modelle

Während beschleunigungs- und ruckbasierte Modelle allein die Dynamik des Fahrzeugs zur Modellierung des Fahrers heranziehen, wird bei positionsbasierten Modellen erstmals das Fahrzeug in Relation zum zur Verfügung stehenden Fahrkorridor gesetzt.

In einer Studie zur Auswirkung der Fahrerfahrung und des Fahrertraining auf das Leistungsvermögen von Motorradfahrern wurden von Crundall et al. die Parameter Position im Fahrstreifen<sup>35</sup> sowie die Varianz der Position untersucht. Die Studie fand auf einem Motorradfahrersimulator im Labor statt, wobei die Probanden zuvor in die drei Gruppen: *Novice*, *Experienced* und *Advanced*, eingeteilt wurden. Die Auswertung der Versuche (siehe Abbildung 2-4) zeigt, dass die durchschnittliche Position der jeweiligen Probandengruppen auf einer 31 km langen Teststrecke mit zunehmender Erfahrung von Mitte des Fahrstreifens in Richtung der Fahrbahn-Mittelmarkierung wandert.<sup>36</sup> Bei der Untersuchung der Position innerhalb der Kurvenfahrt über mehrere Segmente<sup>37</sup> (siehe Abbildung 2-5) wird zudem ersichtlich, dass Fahranfänger, mit einem durchschnittlichen Positionsdelta von ca. vier Fuß, von Anfang bis Ende der Kurvenfahrt, signifikant weniger

---

<sup>33</sup> Vgl. Murphey, Y. L. et al.: Driver's style classification using jerk analysis (2009), S. 2–3.

<sup>34</sup> Das Verhältnis von Fahrzeugbreite (ca. 2 bis 2,55 m) zu Fahrstreifenbreite (2,75m bei Ortsverbindungsstraße bis 3,75m bei BAB) ist für Mehrspurfahrzeuge relativ gering, womit dem Fahrer wenig Spielraum für die Abweichung von der Straßengeometrie bleibt, ohne den eigenen Fahrstreifen zu verlassen.

<sup>35</sup> Die Position wurde in der Studie durch die Entfernung von Fahrbahn-Mittelmarkierung bei einer zweistreifigen Fahrbahn gemessen.

<sup>36</sup> Vgl. Crundall, D. et al.: Study on motorcycle experience and training (2014), S. 85.

<sup>37</sup> Segmente sind auf der y-Achse dargestellt. Segment 1 beschreibt dabei den Kurveneingang und Segment 7 den Kurvenausgang.

Variation der Position aufweisen. Beide erfahrenen Fahrergruppen nutzen den Fahrstreifen bei der Kurvenfahrt dem gegenüber, mit einem Positionsdelta von 7,5 bzw. 6 Fuß, deutlich mehr aus.<sup>38</sup>




Abbildung 2-4: Mittlere Fahrstreifenposition für verschiedene Fahrerfahrerklassen<sup>39</sup>




Abbildung 2-5: Position im Fahrstreifen für einzelne Segmente aller Rechtskurven<sup>40</sup>

Die Linienwahl (Verlauf der Position) der *Advanced* und *Experienced* Fahrer entspricht einem bewusst gewollten Verhalten, bei dem spät und von weit außen in die Kurve eingelenkt wird, um den Kurvenscheitelpunkt in Richtung Kurvenausgang zu verschieben und so eine bessere Übersicht über den Kurvenverlauf zu haben.<sup>41</sup>

## 2.2.2 Manöverbasierte Bewertung des Fahrerverhaltens

### Spurhalteverhalten Pkw

Bossdorf et al. nutzen die Position im Fahrstreifen, um die Parameter eines regelungstechnischen Fahrermodells während der Fahrt zu bestimmen. Dabei wird anhand des Abgleichs der Ist-Position mit einer im Voraus berechneten Soll-Position die Vorausschauzeit sowie die Fahrerverstärkung des kompensatorischen Regelkreises bestimmt. Basierend auf diesen beiden Kenngrößen wird die Stabilitätsreserve des Regelkreises berechnet. Diese dient als Eingangsgröße zur Bewertung des Fahrerleistungsvermögens. Die Autoren weisen nach, dass der objektive Kennwert mit der subjektiven Bewertung

<sup>38</sup> Vgl. Crundall, E. et al.: Experiential differences across rider groups (2012), S. 9–12.

<sup>39</sup> Crundall, D. et al.: Study on motorcycle experience and training (2014), S. 85.

<sup>40</sup> Crundall, E. et al.: Experiential differences across rider groups (2012), S. 12.

<sup>41</sup> Vgl. Spiegel, B.: Die obere Hälfte des Motorrads (2009), S. 82–85.

während einer mehrstündigen Testfahrten korreliert. Ein weiteres Ergebnis ist, dass sowohl Fahrerverstärkung als auch Vorausschauzeit eine Unterscheidung der zwei Probandengruppen *Junge Fahrer* und *Senioren* zulassen.<sup>42</sup>

Mit einem vergleichbaren regelungstechnischen Fahrermodell zeigen W C. Lin et al., dass aus den Parametern eines online gelernten Modells auf die Fahrexpertise eines Fahrers geschlossen werden kann. Die hierzu verwendeten Daten wurden in einer eigens durchgeführten Simulator-Studie aufgenommen. Die Fahrer wurden dabei als *normal* und *expert* klassifiziert.<sup>43</sup>

### Fahrstreifenwechsel Pkw

Ein weiteres Verfahren, das aus der Gruppe um W C. Lin stammt, bewertet die Fahrfertigkeiten anhand der Ausführung eines zuvor definierten doppelten Spurwechsels (DLC) und Spurwechsels innerhalb einer Kurvenfahrt (LCIC). Die Versuche wurden abermals in einem Fahrsimulator durchgeführt und die zwölf Fahrer in drei Klassen *low-skill*, *typical* und *expert* im Anschluss an die Experimente eingeteilt. Zur Klassifikation des Manövers werden aus dem Signal des Lenkradwinkels Merkmale in Form der Koeffizienten der diskreten Fourier-Transformation (DFT)<sup>44</sup> bzw. der diskreten Wavelet-Transformation (WT)<sup>45</sup> extrahiert. Der Klassifikationsschritt erfolgt mittels verschiedener Algorithmen wie Entscheidungsbäumen, Neuronalen Netzen und Support-Vektor-Maschinen sowie deren Fusion. Die Korrektklassifikationsrate<sup>46</sup> der einzelnen Manöver liegt im Bereich von 79-81 % bzw. 87-88 %<sup>47</sup> bei Verwendung der DFT-Koeffizienten. Der Typ des verwendeten Algorithmus hat damit nahezu keinen Einfluss auf die Erkennungsrate. Es konnte zudem gezeigt werden, dass bei Nutzen von 7 per Zufall gezogenen DLC-Datensätzen pro Fahrer eine korrekte Klassifikation von 11 der 12 Fahrer möglich ist.<sup>48</sup>

---

<sup>42</sup> Vgl. Bossdorf-Zimmer, J. et al.: Fingerprint des Fahrers (2011), S. 230.

<sup>43</sup> Vgl. Lin, W. C. et al.: Characterization of Driving Skill Level (2007).

<sup>44</sup> Vgl. Zhang, Y. et al.: Driving Skill Characterization (2010), S. 907–908.

<sup>45</sup> Vgl. Tang, X.: Driving Skill Recognition and Comparison (2009), S. 420–424.

<sup>46</sup> Im Englischen ist hierfür der Begriff Accuracy gebräuchlich.

<sup>47</sup> Abhängig vom gewählten Trainingsdatensatz. Der größere Wert wird nach der Exklusion eines Fahrers aus der Expertengruppe erzielt, da dessen Verhalten den Messdaten zufolge eher einem Normalfahrer entspricht.

<sup>48</sup> Vgl. Zhang, Y. et al.: Driving Skill Characterization (2010), S. 913–915.

Ein kritischer Punkt des gezeigten Verfahrens ist, dass die ausgeführten Manöver nicht explizit annotiert wurden. Anstelle dessen wird angenommen, dass Experten ausschließlich Expertenverhalten zeigen. Tatsächlich zeigt jedoch auch ein Experte in Realität hin und wieder durchschnittliches oder sogar unterdurchschnittliches Verhalten.

### Kurvenfahrt Pkw

Chandrasiri und Kagawa untersuchen in ihren Studien, ob Fahrer der Klassen *High-Skilled* und *Low-Skilled* anhand der Messung von Fahrzeugdynamik und Fahrereingaben während Kurvenfahrten klassifiziert werden können. Hierfür wurden von 16 Fahrern zehn Runden auf einem Rundkurs mit sechs unterschiedlichen Linkskurven in einem Fahrsimulator aufgenommen. Die einzelnen Kurvenfahrten wurden entsprechend der Klasse des Fahrers annotiert.<sup>49</sup> Zur Klassifikation werden Merkmale aus den multivariaten Sensordaten, die zuvor entsprechend der zurückgelegten Strecke im Fahrsimulator indexiert wurden, mittels Hauptkomponenten-Analyse extrahiert. Hierzu werden die einzelnen Messdaten  $\hat{x}_{\text{Sen}}(t)$  der Sensormessgröße *Sen* gemäß Formel 2.4 standardisiert zu  $\hat{x}_{\text{Sen}}(t)$  und in einer Matrix  $X_{\text{Kurve}}$  zusammengefasst.

$$\hat{x}_{\text{Sen},i}(t) = \frac{x_{\text{Sen},i}(t) - \mu(x_{\text{Sen},i})}{\sigma(x_{\text{Sen},i})}. \quad (2.4)$$

$$X_{\text{Kurve}} = [\hat{x}_{\text{Sen},1}(t), \hat{x}_{\text{Sen},2}(t) \dots, \hat{x}_{\text{Sen},n}(t)]^T. \quad (2.5)$$

Die Matrix  $X_{\text{Kurve}}$  ist hierbei kurven- bzw. kurvensegmentspezifisch. Die Hauptkomponentenanalyse erfolgt auf dem Gesamtdatensatz  $X$ , der alle Kurvenfahrten enthält.

$$X = [X_{\text{Kurve},1} \dots X_{\text{Kurve},n}]. \quad (2.6)$$

Die Klassifikation erfolgt anhand der Hauptkomponenten von  $X$  mittels k-Nearest-Neighbor (kNN) Verfahren sowie einer Support Vektor Maschine (SVM). Die Erkennungsraten liegen bei ca. 95 %, wenn die Daten der gesamten Kurve verwendet werden, bzw. bei 85-91 %, wenn nur einzelne Kurvensegmente<sup>50</sup> genutzt werden. Ein weiteres Ergebnis der Fertigkeitklassifikation anhand einzelner Kurvensegmente ist, dass die höchste Erkennungsrate im Segment, welches das Verlassen der Kurve kennzeichnet, erzielt wird. Es wird zudem festgestellt, dass die Erkennungsrate mit kleiner werdendem Umschlingungswinkel bzw. kleiner werdender Krümmung abnimmt.<sup>51</sup>

<sup>49</sup> Vgl. Chandrasiri, N. P. et al.: Driving Skill Classification in Curves (2016), S. 199–200.

<sup>50</sup> Die Kurvenfahrt wurde hierbei in 5 geometrisch gleichlange Kurvensegmente zerlegt, wobei das erste Segment die Anfahrt und das letzte Segment die Abfahrt enthält.

<sup>51</sup> Vgl. Chandrasiri, N. P. et al.: Driving Skill Classification in Curves (2016), S. 204–205.

Kagawa verzichtet bei der Klassifikation der Fahrten des gleichen Datensatzes auf die Merkmalsextraktion und verwendet den Datensatz  $X$  als Eingang für ein Neuronales Netz mit drei Zwischenschichten unterschiedlicher Größe. Das auf den Daten aller Fahrer trainierte Netz erzielt für verschiedene Sensorsignalkombinationen Erkennungsraten von bis zu 98 %.<sup>52</sup> Anhand der Veröffentlichung wird jedoch nicht klar, ob es einen separaten Test- und Trainingsdatensatz gab, oder ob das Ergebnis durch Training und Test auf einem einzigen Gesamtdatensatz zustande kommt.

Osgouei untersucht die Eignung eines Hidden-Markov-modellbasierten (HMM) Distanzmaßes zur Bewertung der Fahrfertigkeiten anhand der Fahrmanöver: Rechts-, Links- und S-Kurven. Der verwendete Datensatz stammt aus wiederholt durchgeführten Fahrversuchen in einem Fahrsimulator. Die Aufgabe der Probanden war es, so gut wie möglich der Fahrstreifenmitte zu folgen. Zur Messung der Fahrfertigkeiten werden die fahrdynamischen Messgrößen Längsbeschleunigung und Gierrate sowie – für den Fall der S-Kurven – die Position im Fahrstreifen verwendet. Für jeden Fahrer wird je ein HMM pro Fahrmanöver trainiert. Die Bewertung der Fahrfertigkeiten erfolgt anschließend aus der Modellabweichung der einzelnen Fahrermodelle mit den Modellen eines als Experten definierten Teilnehmers der Studie.<sup>53</sup> Das Distanzmaß  $D_{\text{HMM}}$  zwischen zwei HMM-Modellen  $\lambda_i$  und  $\lambda_j$  wird dabei nach der Definition von Juang und Rabiner berechnet.<sup>54</sup> Dabei ist  $t_{\text{Seq}}$  die Länge der Sequenz und  $P(O_i, \lambda_i)$  die Likelihood der Beobachtungen  $O_i$  und den Modellparametern  $\lambda_i$  aus dem Modell  $i$ .

$$D(\lambda_i, \lambda_j) = \frac{1}{t_{\text{Seq}}} [\log P(O_i, \lambda_i) - \log P(O_i, \lambda_j)] \quad (2.7)$$

$$D_{\text{HMM}}(\lambda_i, \lambda_j) = \sqrt{D(\lambda_i, \lambda_j)^2 + D(\lambda_j, \lambda_i)^2} \quad (2.8)$$

Die Ergebnisse des ersten Teils der Studie von Osgouei zeigen, dass dieses Distanzmaß das Clustering der Fahrer in die drei Gruppen *high-*, *medium-* und *low-skilled* ermöglicht, dessen Ergebnisse sich, bis auf das Vertauschen zweier Fahrer, mit den subjektiven Bewertungen des Experten decken.<sup>55</sup> Im zweiten Teil der Studie wird die Korrelation zwischen dem Distanzmaß  $D_{\text{HMM}}$  und den subjektiven Bewertungen der Probanden bzw. objektiven Kennwerten für zwei verschiedene S-Kurven-Manöver untersucht. Es wird festgestellt, dass das HMM-basierte Distanzmaß mit einem Korrelationskoeffizienten von

---

<sup>52</sup> Vgl. Kagawa, T.; Chandrasiri, N. P.: Deep Learning Driving Skills in Curves (2017), S. 3.

<sup>53</sup> Osgouei, R. H. et al.: HMM based Driving Skill Measure (2013).

<sup>54</sup> Vgl. Juang, B.-H.; Rabiner, L. R.: Probabilistic Distance for HMM (1985), S. 392–395.

<sup>55</sup> Vgl. Osgouei, R. H. et al.: HMM based Driving Skill Measure (2013), S. 175.

$\rho = 0.52$  nicht besser geeignet ist, die Fahrfertigkeiten eines Fahrers zu bestimmen als der objektive Kennwert der Spurabweichung von der Fahrstreifenmitte.<sup>56</sup>

Zur Bestimmung der Korrelation wurde der Pearsons Roh Test verwendet und die Fahrer auf einer subjektiven Skala von 0 bis 100 bewertet. Dies impliziert jedoch, dass der Experte bis auf einen Punkt genau die Fertigkeiten der Fahrer einschätzen kann. Die Ergebnisse der Korrelation im zweiten Teil der Studie sind aufgrund der genutzten kardinalen Bewertungsskala damit zumindest kritisch zu betrachten.

### **Abbiegen von Motorrädern**

Beim Abbiegen handelt es sich grundsätzlich ebenfalls um eine Kurvenfahrt. Der Kurvenradius liegt hier jedoch im Bereich weniger Meter, weshalb auch die Fahrgeschwindigkeiten grundsätzlich niedrig sind. Als Konsequenz sinkt der Einfluss der Kreiselkräfte auf die Stabilität des Motorrads und der Einfluss des Fahrers auf die dynamische Stabilität steigt. Zur Bewertung des Fahrers anhand solcher Abbiegemanöver haben Yoneta et al. ein patentiertes Verfahren entwickelt.

Die Methode basiert auf der Detektion von Abbiegemanövern beim Überschreiten eines Schwellwerts für das Signal der Gierrate. Aus den gespeicherten Daten werden im Anschluss an das Abbiegemanöver drei Kennwerte berechnet, die folgendes beschreiben:

1.  $K_S$ : die Fahrzeugstabilität während des Abbiegens,
2.  $K_T$ : die Trajektorien-Wahl und -Ausführung,
3.  $K_H$ : die Kopfstabilität bzw. das Blickverhalten.

Die drei Kennwerte werden nach einem sehr ähnlichen methodischen Vorgehen berechnet. Im ersten Schritt werden ein oder mehrere entsprechende Zeitsignale mittels Tief- und/oder Bandpassfilter gefiltert. Im weiteren Verlauf dieses Abschnitts bezeichnet  $\tau_i(t)$  das tiefpassgefilterte und  $\zeta_i(t)$  das bandpassgefilterte Signal einer Messgröße. Von den gefilterten Signalen wird anschließend das Integral der Absolutwerte bestimmt und, sofern notwendig (siehe Formel 2.11), mit der diskreten zeitlichen Länge der Signalsequenz normiert.

Die Fahrzeugstabilität  $K_S$ , siehe Formel (2.10), ist definiert als die mit den Faktoren  $w_i$  gewichtete Summe der Verhältnisse von tieffrequenten zu hochfrequenten Signalanteilen der Messgrößen Roll-, Nick- und Gierrate, siehe Formel (2.9). Ein hoher Wert deutet auf ein Abbiegen mit wenigen Instabilitäten hin während ein niedriger Wert im Umkehrschluss auf Instabilitäten hindeutet.

---

<sup>56</sup> Vgl. Osgouei, R. H. et al.: HMM based Driving Skill Measure (2013), S. 178.



$$K_{S,i} = \frac{\int_0^{t_{\text{seq}}} |\tau_i(t)| dt}{\int_0^{t_{\text{seq}}} |\zeta_i(t)| dt} \quad (2.9)$$

$$K_S = \sum_{i=1}^N w_i \cdot K_{S,i} \quad (2.10)$$

Der Kennwert der Kopfstabilität  $K_H$  wird analog dem Verfahren der Fahrzeugstabilität mit den Messgrößen Nick- und Gierrate des Kopfes berechnet.

Der verbliebene Kennwert  $K_T$ , für die Bewertung der Trajektorie, wird rein aus dem tiefpassgefilterten Signal des Rollwinkels und des Lenkwinkels bestimmt. Ein hoher Wert wird als positiv interpretiert, da dies auf einen glatten Verlauf des gefilterten Signals zurückzuführen ist, der für ein geplantes Verhalten spricht.

$$K_T = \sum_{i=1}^N w_i \cdot \frac{1}{t_{\text{seq}}} \int_0^{t_{\text{seq}}} |\tau_i(t)| dt \quad (2.11)$$

Alle drei Kennwerte werden vor der Fusion zu einer Gesamtbewertung in Abhängigkeit der Parameter Kurvenradius und Reibwert skaliert.<sup>57</sup>

Zu dem beschriebenen Verfahren existiert nur die Offenlegungsschrift der Patenterteilung. Eine Bewertung der Methode sowie eine Spezifikation der Parameter, beispielsweise der Eckfrequenzen der Tief- und Bandpassfilter, existieren nicht.

---

<sup>57</sup> Vgl. Yoneta, K. et al.: Offenlegung Motorcycle Rider Assessment Device (2010).

## 2.3 Ableitung des Forschungsbedarfs

Im Bereich der Fahrermodellierung von Motorradfahrern, insbesondere für die Verwendung in Fahrerassistenzsystemen, ist das g-g-Diagramm bzw. die statistische Verteilung der gefahrenen Rollwinkel das vorherrschende Modell für die Kurvenfertigkeiten und die Fahrexpertise des Fahrers. Der maximal erreichte Rollwinkel wird dabei als Maß für die Fahrfertigkeiten des Fahrers angenommen.<sup>58,59</sup> Tatsächlich misst dieser Kennwert jedoch erst einmal die Entfernung vom fahrphysikalischen Limit und ist damit ein Maß für die Risikobereitschaft des Fahrers. Es ist allerdings nicht von der Hand zu weisen, dass Fahrerfahrung auch mit zunehmender Kontrolle des Fahrzeugs im Grenzbereich einhergeht. Die angesprochene Kontrolle wird allerdings nicht durch einzelne Messpunkte ohne zeitlichen Zusammenhang messbar. Zudem kommt hinzu, dass gerade im öffentlichen Straßenverkehr die Devise niemals sein sollte, das Risiko zu maximieren. Vielmehr sollte immer eine Sicherheitsreserve eingeplant werden, um auf unvorhergesehene Ereignisse reagieren zu können. Hinzu kommen Einflussfaktoren, wie beispielsweise die Verkehrslage, der Fahrbahnzustand oder ein Geschwindigkeitslimit, die den Fahrer davon abhalten, zum aktuellen Zeitpunkt an seiner persönlichen Grenze zu operieren.

Die im Stand der Forschung identifizierten Modelle sind zusammengefasst entweder nicht dazu geeignet die tatsächlichen Fahrfertigkeiten innerhalb einer beliebigen Kurvenfahrt zum aktuellen Zeitpunkt zu bestimmen, oder wurden diesbezüglich noch nicht im Realverkehr untersucht und konnten somit weder verifiziert noch falsifiziert werden.

Die zentrale Fragestellung, mit der sich in Rahmen dieser Arbeit befasst wird ist daher:

*Wie differenziert sind die Fahrfertigkeit einzelner individueller Fahrer in Kurvenfahrt im Realverkehr bestimmbar?*

Mit Bezug auf den Stand der Forschung sowie der dargelegten Motivation ist die zentrale Fragestellung in einzelne Forschungsfragen untergliedert:

F1.a: *In welcher Abstufung sind Fahrfertigkeiten differenzierbar?*

F1.b: *Wie zuverlässig und schnell kann eine Zuordnung der Fahrfertigkeiten erfolgen?*

Das patentierte Verfahren von Yoneta et al. zum Abbiegeverhalten von Motorradfahrern gibt Anhaltspunkte zur Berechnung eines Bewertungsmaßes.<sup>60</sup> Die Offenlegungsschrift

---

<sup>58</sup> Biral, F. et al.: An intelligent curve warning system for powered two wheel vehicles (2010).

<sup>59</sup> Spiegel, B.: Die obere Hälfte des Motorrads (2009).

<sup>60</sup> Yoneta, K. et al.: Offenlegung Motorcycle Rider Assessment Device (2010).

lässt jedoch zentrale Fragen offen, zu denen auch keine weiteren Arbeiten bekannt sind. Grundsätzlich stellt sich die Frage:

*F2: Welche Metriken und Verfahren sind geeignet, um die allgemeine Kurvenfahrt hinsichtlich Fahrfertigkeiten zu bewerten?*

Diese Frage wird wie folgt weiter untergliedert:

*F2.a: Welche Frequenzanteile der Rollbewegung ermöglichen einen Rückschluss auf die Manöverausführung?*

Im Kontext der Bewertung der Manöverausführung ist es denkbar, nicht etwa ein Idealverhalten als positive Referenz zu definieren, was aufgrund unterschiedlich möglicher Wahl der Fahrzeugtrajektorie im Fahrsteifen schwierig ist, sondern Verhaltensmuster zu suchen, die auf einen expliziten Fahrfehler hindeuten. Ein Teil dieser Arbeit beschäftigt sich aus diesem Grund mit den Fragen:

*F2.b: Welche Fahrfehler treten in der Kurvenfahrt auf und sind Fahrfehler als Maß zur Fahrfertigkeitsbewertung geeignet?*

Die dritte Hauptforschungsfrage bezieht sich auf die in der zentralen Fragestellung genutzte Formulierung „in Kurvenfahrt ... im Realverkehr“ und wird wie folgt formuliert:

*F3: Mit welchen Methoden und in welcher Qualität lassen sich beliebige Kurvenfahrten zur Auswertung der Fahrfertigkeiten generalisieren?*

Alle diese Fragestellungen werden anhand der Messdaten von Realfahrten im öffentlichen Straßenverkehr untersucht. Gegenüber dem Stand der Forschung stellt dies eine weitere Neuerung dar, da bei der Klassifikation der Fahrexpertise nur ideale Messdaten aus einem Fahrsimulator verwendet wurden. Insbesondere die Schätzung der Position innerhalb der Fahrbahn- und Fahrstreifenbegrenzung stellt in der Realität aufgrund des Roll- und Nickwinkels eine Herausforderung dar.

## 3 Untersuchungswerkzeuge & Methoden

### 3.1 Versuchsfahrzeug

Zur Untersuchung der Fragestellungen dieser Arbeit wurde für die Versuchsfahrten und die Probandenstudie ein handelsübliches Motorrad des Typs: Honda NC 700X verwendet. Das technische Datenblatt ist in Tabelle A-1 im Anhang beigelegt. Das Fahrzeug befand sich bis auf die zusätzlich angebrachte Messtechnik im Serienzustand. Diese wurde so angebracht, dass sie zu keiner Beeinträchtigung der Probanden sowie deren Verhalten während der Studie führt.

#### 3.1.1 Messtechnik

Um das Fahrerverhalten in Kurvenfahrt zu untersuchen, ist die Messung der Fahrereingabegrößen sowie der daraus resultierenden Fahrzeugdynamik notwendig. Die Architektur des Messtechnikaufbaus ist in Abbildung 3-1 abgebildet. Die Synchronisation der Inertialmesstechnik mit den am Analog-Digital-Wandler angeschlossenen Sensoren erfolgt softwareseitig über die Messsoftware LabVIEW der Firma National Instruments.

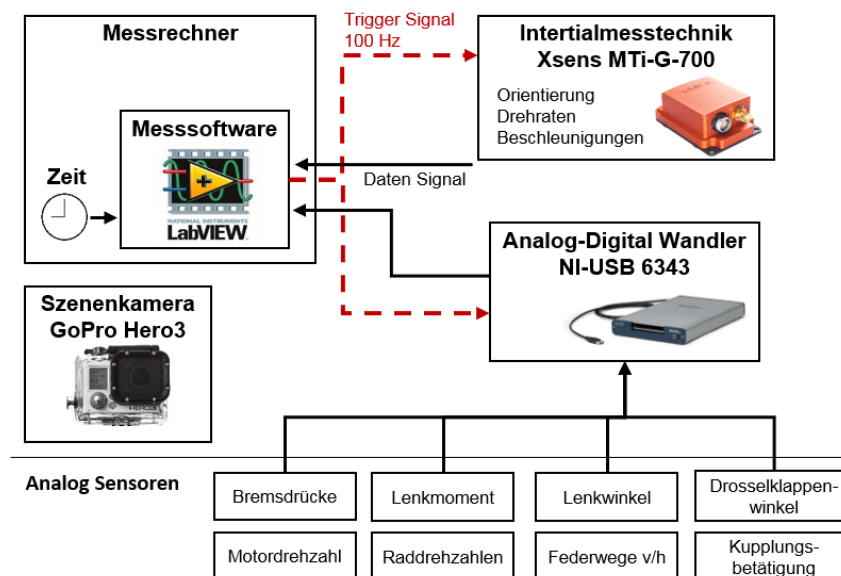


Abbildung 3-1: Architektur des Messtechnikaufbaus des Versuchsfahrzeugs<sup>61</sup>

<sup>61</sup> Bildquellen: National Instruments, Xsens Technologies B.V., GoPro Incorporation.

Die Daten werden zeitgesteuert mit einer Frequenz von 100 Hz am Sensor bzw. AD-Wandler asynchron abgegriffen und zusammen mit dem Zeitstempel der Systemzeit abgespeichert. Die Bilddaten der Szenenkamera werden hingegen lokal im Gerät abgespeichert und erst im Nachgang der Versuchsfahrt mit dem in Abschnitt 3.1.3 beschriebenen Verfahren synchronisiert.

#### Inertialmesstechnik

Die Messung der Fahrzeugdynamik erfolgt mit der Inertialmesseinheit MTi-G-700 der Firma Xsens Technologies B.V.. Bei dem Sensor handelt es sich um eine vollintegrierte IMU mit GNSS-Empfänger und Barometer, deren Messgrößen mit einem erweiterten Kalman-Filter fusioniert und korrigiert werden. Die Spezifikation der Genauigkeit der 3-D-Fahrzeugorientierung im lokalen erdfesten Koordinatensystem ist in Tabelle 3-1 aufgeführt. Die Inertialmesseinheit ist so konfiguriert, dass die Daten mit einer Frequenz von 200 Hz intern verarbeitet und bereitgestellt werden.

Tabelle 3-1: Genauigkeit der 3D-Orientierung der IMU MTi-G-700<sup>62</sup>

		Typisch	Maximal
Roll- & Nickwinkel	Statisch	0.2°	0.25°
	Dynamisch	0.3°	1.0°
Gierwinkel		1.0°	N/A

#### Federwegmessung

Die Berechnung des Federwegs an Vorder- und Hinterrad des Fahrzeugs ist für die extrinsische Kalibrierung der Szenenkamera gegenüber der Fahrbahnebene notwendig. Die Messung des Federwegs am Vorderrad erfolgt über ein Linear-Potentiometer<sup>63</sup>, das parallel zur Telegabel angebracht ist. Am Hinterrad wird der Schwingendrehwinkel über ein Koppelgestänge und einen Hall-Sensor<sup>64</sup> gemessen und daraus die vertikale Radbewegung berechnet. Die Signale der Sensoren werden mit dem Analog-Digital-Wandler mit einer Frequenz von 100 Hz abgetastet.

---

<sup>62</sup> Xsens Technologies B.V.: MTi User Manual (2015), S. 32.

<sup>63</sup> Typ: SA-LP250/350-000 der Firma 2D Debus & Diebold Messsysteme GmbH

<sup>64</sup> Typ 9138000050 der Firma AB Elektronik

## Fahrzeuggeschwindigkeit

Die Fahrzeuggeschwindigkeit wird aus der induktiv am ABS-Sensorkranz mit 50 Hz gemessenen Raddrehzahl  $f_{\text{Rad}}$ , dem Rollwinkel  $\varphi$  sowie dem Reifenradius  $r_0$  und dem Reifenkonturradius<sup>65</sup>  $r_{\text{Kontur}}$  gemäß dem Modell nach Formel (3.1) berechnet. Das Modell kompensiert den vermeintlichen Geschwindigkeitsanstieg während einer Kurvenfahrt, welcher durch den veränderten Abrollradius entsteht.

$$v_x = 2 \cdot \pi \cdot f_{\text{Rad}} \cdot (r_0 - \sin|\varphi| \cdot r_{\text{Kontur}}) \quad (3.1)$$

### 3.1.2 Messdaten-Vorverarbeitung

Die asynchron mit 100 Hz bzw. 50 Hz, im Fall der Raddrehzahlsensoren, abgetasteten Messdaten werden im Nachgang an die Messungen auf einen gemeinsamen Zeitstempel mittels linearer Interpolation synchronisiert. Als Referenzzeitstempel wird die Zeit der Messung der Inertialmesseinheit definiert.

Die mit einer Frequenz von 100 Hz synchronisierten Messdaten werden anschließend tiefpassgefiltert um hochfrequente Störeinflüsse zu unterdrücken, welche aus hochfrequenten Straßenanregungen und Motorvibrationen resultieren. Da die Filterung offline in der Nachverarbeitung erfolgt, wird phasenverzugsfrei geglättet, indem der Filter zuerst vorwärts auf die Ursprungssignale angewendet wird und anschließend ein zweites Mal auf das zeitlich gespiegelte Signal. Das dabei eingesetzte FIR-Filter besitzt die Ordnung<sup>66</sup> 40 und eine Durchlasseckfrequenz von 5 Hz bei einer Unterdrückungseckfrequenz von 10 Hz, da angenommen wird, dass fahrdynamische Änderungen mit einer höheren Frequenz nicht vom Fahrer beabsichtigt herbeigeführt werden.

Zum Abschluss der Vorverarbeitung wird das Tiefpass-gefilterte Signal mit einer Frequenz von 10 Hz unterabgetastet. Abbildung 3-2 zeigt den Vergleich der ungefilterten Rohdaten sowie der vorverarbeiteten Daten. Die Signalverläufe der Daten für den Rollwinkel sind visuell nicht voneinander zu unterscheiden. Dies ist auf die interne Verarbeitung der Messdaten innerhalb der IMU mittels Kalmanfilter zurückzuführen, welches laut Spezifikation des Herstellers mit einer Frequenz von 10 Hz arbeitet. Für den Verlauf der Rollrate ist eine Glättung des Signals sichtlich erkennbar ohne Maxima und Minima zu verfälschen.

---

<sup>65</sup> Die Parameter sind in Abbildung 2-2 dargestellt.

<sup>66</sup> Gleichbedeutend mit der Anzahl der Koeffizienten plus 1.




Abbildung 3-2: Vergleich ungefilterter und vorverarbeiteter Daten für Rollwinkel und Rollrate

### 3.1.3 Video-Synchronisation

Die aufgezeichneten Bilddaten der Szenenkamera sind in erster Funktion zum Verständnis der Messdaten und den auftretenden Szenarien notwendig. Für diese Funktion liegt die Anforderungen an die zeitliche Synchronität der Video- und Fahrzeugmessdaten im Bereich von wenigen Sekunden, was durch zeitgleiches manuelles Starten der Aufnahmen umsetzbar ist. Die Auswertung des Bildmaterials ermöglicht, weitere Kenngrößen der Kurvenfahrt zu extrahieren, die nicht in den Messdaten der Fahrdynamik enthalten sind. Beispiel hierfür ist die Position im Fahrstreifen, die als Zeitreihe Rückschluss auf die Fahrzeugtrajektorie zulässt und damit eine potenzielle Messgröße für das Fahrerverhalten ist. Daraus resultieren höhere Anforderungen an die Synchronität, die im Bereich der Abtastrate der verwendeten Fahrdynamikdaten von 10 Hz liegen.

Zur Synchronisation wird aus den Bilddaten die Rollbewegung des Motorrads berechnet. Aus Einzelbildern des Videos werden mit dem SURF-Verfahren<sup>67,68</sup> markante und rotationsinvariante Merkmale extrahiert. Basierend auf den Merkmalsvektoren wird die geometrische Bildtransformation und damit auch die Verdrehung zwischen zwei Einzelbildern berechnet. Mit diesem Verfahren wird für zwei Sequenzen, von jeweils 30 Sekunden (300 Bildern), zu Beginn und zum Ende des Videos die Fahrzeugrollrate bestimmt. Die

<sup>67</sup> Bay, H. et al.: SURF: Speeded Up Robust Features (2006).

<sup>68</sup> Genutzt wurde die Implementierung in MATLAB R2016a.

zeitliche Zuordnung der Bilder zu den Messdaten erfolgt abschließend durch die Korrelationen der beiden Sequenzen mit der per IMU gemessenen Rollrate. Abbildung A-2 im Anhang zeigt die erzielte zeitliche Korrelation für eine exemplarische Versuchsfahrt.

Zwischen den beiden Startpunkten der korrelierten Sequenzen wird die zeitliche Bildzuordnung linear interpoliert, da die Bildrate des aufgezeichneten Videos von 59,9401 Hz nicht exakt auf ein ganzzahliges Vielfaches von 10 Hz heruntergebrochen werden kann.

## 3.2 Bestimmung der Position im Fahrstreifen

Die Messung der lateralen Position des Versuchsfahrzeugs während den Messfahrten erfolgt offline mittels Bildverarbeitungsverfahren. Als Referenzpunkt für die Messung wird der auf die Fahrzeugsymmetrieebene projizierte Vorderrad-Aufstandspunkt verwendet. Das Verfahren basiert auf den aufgezeichneten, synchronisierten und bereits rektifizierten Kamera-Bilddaten, sowie der gemessenen Fahrzeugorientierung aus Intertialmessdaten und Federwegsensoren. Die Gesamtmethode zur Bestimmung der Fahrzeugposition setzt sich aus den folgenden Schritten zusammen, auf die im Anschluss näher eingegangen wird:

1. Extraktion von Bildpunkten mit Fahrstreifen-Markierungen aus den RGB Bildern der Szenenkamera.
2. Transformation der als Fahrstreifen-Markierung klassifizierten Bildpunkte von 2D-Bildkoordinaten in 2D-Weltkoordinaten<sup>69</sup>.
3. Clustering und Regression der zeitlich akkumulierten Punkte zu zusammengehörigen Fahrstreifenmarkierungen.
4. Berechnung der Position des Fahrzeugs innerhalb des eigenen Fahrstreifens.

### Extraktion von Bildpunkten

Die Detektion und Klassifikation von Fahrstreifenmarkierungen lässt sich nach heutigen Stand der Technik sowohl mit Verfahren, bei denen klassische Bildmerkmale wie Kanten, Ecken<sup>70,71</sup> oder Helligkeitsregionen<sup>72</sup> extrahiert werden, als auch mit tiefen Neuronalen

---

<sup>69</sup> Die z-Position (Höhe) der Fahrstreifenmarkierung wurde vernachlässigt, siehe Erklärung im dazugehörigen Abschnitt.

<sup>70</sup> Wang, Y. et al.: Lane detection and tracking using B-Snake (2004).

<sup>71</sup> Lindner, P. et al.: Robust geometric lane feature extraction (2010).

<sup>72</sup> Cáceres Hernández, D. et al.: Lane region detection (2016).



Netzen lösen. Dabei kann bei Letzteren unterschieden werden, ob das Netz speziell für den Zweck der Fahrstreifenerkennung trainiert wurden<sup>73,74</sup> oder ob Fahrstreifen ein Bestandteil, d.h. eine Klasse, in einem Netz zur semantischen Segmentierung, wie z.B. SegNet<sup>75,76</sup> oder PSPNet<sup>77</sup> sind.

Die Probandenversuche zur Untersuchung der Fahrfertigkeiten wurden stets unter guten Lichtverhältnissen, d.h. ohne erkennbaren Einfluss auf die Bildauswertung, von Mai bis Oktober durchgeführt. Die Fahrstreifenmarkierungen sind auf der Strecke in guter Qualität erkennbar und deutlich vom Hintergrund, hauptsächlich Vegetation, unterscheidbar. Ferner gibt es auf dem ausgewerteten Teil der Strecke<sup>78</sup> keine Zebrastreifen oder parallel zur Fahrbahn verlaufende Gehwege. Aufgrund der genannten Randbedingungen und dem Fehlen eines annotierten Referenzdatensatz für Fahrstreifenmarkierungen, der auch die Besonderheit der hohen motorradspezifischen Rollwinkel abdeckt, basiert das Verfahren zur Fahrstreifenerkennung auf klassischen Methoden der Bildverarbeitung.

Die Detektion von Fahrstreifenmarkierungen erfolgt durch die Überlagerung von unterschiedlichen Verfahren, die zum einen Helligkeits- und Farbmerkmale und zum anderen Kantenmerkmale extrahieren. Der Prozess ist in Abbildung 3-3 dargestellt.

Im ersten Schritt werden Binärbilder durch Anwenden von einfachen Schwellwertverfahren auf die Pixel-Intensitätswerte unterschiedlicher Farbraumkanäle erzeugt. Die Fahrbahn lässt sich gut im blauen Kanal des RGB-Farbraums von Vegetation abheben. Allerdings tritt der Himmel ebenfalls im blauen Kanal hervor. Aus diesem Grund wird ausschließlich die untere Bildregion ausgewertet. Da die Fahrbahn eine zusammenhängende Fläche darstellt, werden die identifizierten Pixel-Regionen zusätzlich anhand der Anzahl zusammenhängender Pixel gefiltert. Ein zweites Binärbild wird mittels Schwellwertverfahren auf dem Hellwert (V) im HSV-Farbraums erzeugt. Der Hellwert eignet sich um Regionen mit hoher Helligkeit, wie sie typischerweise Fahrstreifenmarkierungen aufweisen, zu identifizieren. Um Regionen unterschiedlicher Helligkeiten innerhalb eines Bildes auswerten zu können, die typischerweise durch Schatten entstehen, wird vor dem Schwellwertverfahren der Kontrast im Bild mittels CLAHE<sup>79</sup>-Verfahren angepasst.

---

<sup>73</sup> Davy Neven et al.: Towards End-to-End Lane Detection: an Instance Segmentation Approach (2018).

<sup>74</sup> Xingang Pan et al.: Spatial As Deep: Spatial CNN for Traffic Scene Understanding (2017).

<sup>75</sup> Alex Kendall et al.: Bayesian SegNet: Model Uncertainty in Deep Convolutional Encoder-Decoder Architectures for Scene Understanding (2015).

<sup>76</sup> Informationen und Demo abrufbar unter <http://mi.eng.cam.ac.uk/projects/segnet/>

<sup>77</sup> Hengshuang Zhao et al.: Pyramid Scene Parsing Network (2016).

<sup>78</sup> Die Ortsdurchfahrt auf Strecke B fließt nicht in die Auswertung mit ein.

<sup>79</sup> Contrast-limited adaptive histogram equalization (CLAHE), Implementierung in MATLAB R2016a.

Die beiden so ermittelten Binärbilder werden durch logische UND Verknüpfung miteinander kombiniert, siehe Bild 3 in Abbildung 3-3.

Ein weiteres Binärbild wird durch Kantendetektion mittels Sobel-Operator auf dem V-Kanal des HSV-Bildes generiert. Anschließend werden Kanten herausgefiltert, die weniger als 30 zusammenhängende Pixel aufweisen, da die äußeren Fahrstreifenbegrenzungsmarkierungen in der Regel komplett zusammenhängend sind. Dies gilt ebenfalls für die unterbrochene Mittelmarkierung, die innerhalb einer Distanz von 10 m vor der Kamera liegen. Ein weiterer Verarbeitungsschritt, zur finalen Erstellung des dritten Binärbilds besteht darin, die Bereiche zwischen zwei detektieren Kanten zu erweitern, d.h. diese ebenfalls als Fahrstreifenmarkierung zu klassifizieren.

Die finalen Kandidaten für Fahrstreifenmarkierungen werden durch die logische Verknüpfung der beiden Binärbilder aus Kanten- und Farbraummerkmalen erzeugt.

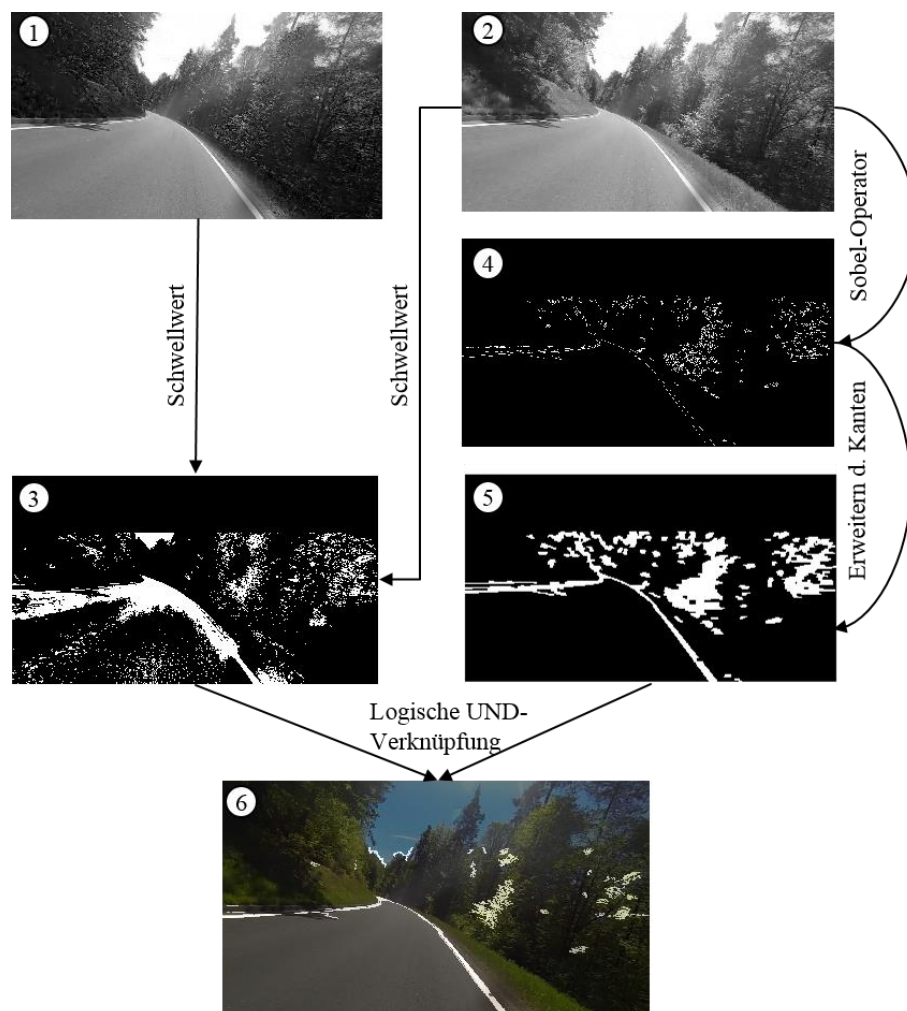


Abbildung 3-3: ①: Grauwertbild des blauen Kanals des RGB-Bildes. ②: Grauwertbild des V-Kanals des in den HSV-Farbraum transformierten RGB-Bilds. ③: Binärbild aus den Farbraum-Merkmalen von ①&②. ④: Mittels Sobel-Operator extrahierte Kantenmerkmale aus ②. ⑤: Aus Kantendetektion abgeleitetes Binärbild der Fahrstreifenmarkierungen. ⑥: Originalbild mit überlagerten Detektionen für Fahrstreifenmarkierungen

Wie bereits in Bild 6 von Abbildung 3-3 zu erkennen kommt es bei dem genutzten Verfahren zu Fehldetektion von Fahrstreifenmarkierungen in der Vegetation und im Bereich der Grenze zum Himmel auftreten. Die bereits in diesem Kapitel zitierten CNNs weisen im Cityscape Benchmark<sup>80</sup> IoU<sup>81</sup>-Übereinstimmungskennwerte für die Detektion von Fahrbahn und Fahrbahnmarkierungen sowie der dazugehörigen Referenz von über 98% auf, sodass bei Einsatz dieser Verfahren möglicherweise weniger Fehldetektionen auf Bildebene auftreten. Für die Untersuchungen innerhalb dieser Arbeit ist die erzielte Fahrstreifenerkennung auf Bildebene jedoch ausreichend, da die nachfolgenden Schritte zur Bestimmung der Fahrzeugposition im Fahrstreifen die Fehldetektionen kompensieren.

#### **Transformation der Fahrstreifenmarkierung ins horizontierte Vorderrad-Koordinatensystem**

Zur Bestimmung der Fahrzeugposition werden die in Bildkoordinaten detektierten Fahrstreifenmarkierungen mittels der intrinsischen und extrinsischen Kameraparameter sowie gemessenen 3D-Fahrzeugorientierung und Fahrzeugkinematik ins horizontierte Vorderrad Koordinatensystem transformiert.

Der betrachtete Ausschnitt um das Fahrzeug, in Form eines Gitternetzes, beginnt aufgrund des Kamera-Sichtbereichs bei  $x_{vh} = 1,5$  m und endet bereits bei  $x_{vh} = 10$  m. Die Diskretisierung beträgt  $\Delta x_{Git} = 0,25$  m. In lateraler Richtung beginnt das Gitter bei  $y_{vh} = -8$  m und endet  $y_{vh} = +8$  m, um selbst am jeweils äußersten Rand des Fahrstreifens die gegenüberliegende äußere Fahrstreifenmarkierung detektieren zu können. Die Diskretisierung des Gitters in laterale Richtung ist mit  $\Delta y_{Git} = 0,05$  m wesentlich feiner gewählt, da die Breite der Fahrstreifenmarkierungen, in Deutschland, außerhalb von Autobahnen, zwischen 12 und 25 Zentimeter beträgt.

Die Betrachtung der Fahrstreifenmarkierung nur im unmittelbaren Umfeld des Fahrzeugs ist gewählt, da in diesem Bereich der Projektionsfehler, durch fehlerbehaftete Messungen der Fahrzeugorientierung gegenüber der Fahrbahn oder der Verletzung der Annahme einer ebenen Fahrbahn, die spätere Auswertung der Position nicht zu stark beeinträchtigt.

Jeder Zelle des diskreten Gitters wird über die nachfolgenden Transformationsvorschriften ein Bildpunkt zugeordnet. Im ersten Schritt werden die Koordinaten der Zelle  $(x_{vh,Git}, y_{vh,Git}, z_{vh,Git})$ , die im Horizontierten Vorderradkoordinatensystem gegeben ist, in Kamerakoordinaten  $(x_{Kam}, y_{Kam}, z_{Kam})$  entsprechend Formel (3.2) umgerechnet.

---

<sup>80</sup> Cordts, M. et al.: Cityscapes Benchmark Suite (2016).

<sup>81</sup> IoU: Intersection over Union. Auch bekannt als Jaccard Koeffizient.

$$\begin{pmatrix} x_{\text{Kam}} \\ y_{\text{Kam}} \\ z_{\text{Kam}} \end{pmatrix} = R_{\text{Kam} \rightarrow \text{Mot}} \cdot \left[ R_{\text{Mot} \rightarrow \text{vh}} \cdot \begin{pmatrix} x_{\text{vh}} \\ y_{\text{vh}} \\ z_{\text{vh}} \end{pmatrix} - T_{\text{Mot, Kam} \rightarrow \text{vh}} \right] \quad (3.2)$$

Dabei beschreibt  $R_{\text{Mot} \rightarrow \text{vh}}$  die Rotationmatrix zwischen horizontalen Vorderradkoordinaten und fahrzeugfesten Koordinaten,  $T_{\text{Mot, Kam} \rightarrow \text{vh}}$  den Offset zwischen Kamera und Vorderradaufstandspunkt in fahrzeugfesten Koordinaten und  $R_{\text{Kam} \rightarrow \text{Mot}}$  die Rotationsmatrix zwischen Kamera- und Fahrzeug-Koordinatensystem.

Anschließend werden die Bildkoordinaten  $(x_{\text{Bild}}, y_{\text{Bild}})$  durch die Transformation mit den intrinsischen Kameraparametern gemäß Formel (3.3) bestimmt. Dabei ist  $b$  die Brennweite der Kamera und  $(x_{\text{Bild, optZent, Pix}}, y_{\text{Bild, optZent, Pix}})$  das optische Zentrum des Bildes, beides angegeben in Pixel.

$$\begin{pmatrix} x_{\text{Bild}} \\ y_{\text{Bild}} \end{pmatrix} = \begin{pmatrix} \frac{x_{\text{Kam}}}{z_{\text{Kam}}} \\ \frac{y_{\text{Kam}}}{z_{\text{Kam}}} \end{pmatrix} \cdot \begin{pmatrix} b_{x, \text{Pix}} \\ b_{y, \text{Pix}} \end{pmatrix} + \begin{pmatrix} x_{\text{Bild, optZent, Pix}} \\ y_{\text{Bild, optZent, Pix}} \end{pmatrix} \quad (3.3)$$

Sofern die Bildkoordinaten  $(x_{\text{Bild}}, y_{\text{Bild}})$  einer Gitterzelle als Fahrstreifenmarkierung im Binärbild des vorangegangenen Schrittes klassifiziert wurde, werden die Gitterkoordinaten  $(x_{\text{vh, Git}}, y_{\text{vh, Git}})$  mit Zeitstempel zwischengespeichert.

Für die Transformation ist von zentraler Bedeutung, dass Lage und Orientierung der Kamera gegenüber der Fahrbahnebene stets präzise geschätzt werden um Projektionsfehler gering zu halten. Für die Rollbewegung um die Fahrzeug-Längsachse wird der gemessene Rollwinkel der IMU genutzt. Dadurch entsteht jedoch ein Projektionsfehler, sobald die Fahrbahnebene zur Seite, d.h. quer zur Fahrstreifen-Längsachse abfällt. Dieser Fehler wird bewusst vernachlässigt, da er im Gegensatz zum Fehler aus der Nickwinkelschätzung gegenüber der Fahrbahn gering ausfällt. Zur Schätzung des Nickwinkels der Kamera gegenüber der Fahrbahn wird auf die verbaute Federwegs-Sensorik und das vereinfachte Nickmodell in Formel (3.4) zurückgegriffen, da auf der gegebenen Versuchsstrecke größere Fahrbahnsteigungen und -gefälle auftreten. Der Nickwinkel der IMU eignet sich hier aufgrund der Referenzierung auf die Erdoberfläche nicht.

Der vereinfachte Nickwinkel  $\tilde{\theta}_{\text{vh}}$  im horizontalen Vorderrad Koordinatensystem wird über die Federwegdifferenzen am Vorderrad  $\Delta s_{\text{Fed, v}}$  und am Hinterrad  $\Delta s_{\text{Fed, h}}$ , siehe Formel (3.6) und (3.7), gegenüber der Ausgangslage mit Formel (3.5) und der Annahme eines statischen Lenkkopfwinkels  $\varepsilon_{\text{Fed, v}}$  und Radstands  $l$  angenähert. Der für die Bildtransformation verwendete Nickwinkel  $\theta_{\text{h}}$  wird anschließend mittels Formel (3.4) bestimmt.

$$\theta_{\text{vh}} = \tan^{-1} \frac{\Delta s_{\text{Fed, v}} \cdot \sin(\varepsilon_{\text{Fed, v}} + \tilde{\theta}_{\text{h}}) + \Delta s_{\text{Fed, h}}}{l \cdot \cos(\tilde{\theta}_{\text{h}})} \quad (3.4)$$

$$\tilde{\theta}_{\text{vh}} = \tan^{-1} \frac{\Delta s_{\text{Fed, v}} \cdot \sin \varepsilon_{\text{Fed, v}} + \Delta s_{\text{Fed, h}}}{l} \quad (3.5)$$

$$\Delta s_{\text{Fed},v} = s_{\text{Fed},v,0} - s_{\text{Fed},v} \quad (3.6)$$

$$\Delta s_{\text{Fed},h} = s_{\text{Fed},h,0} - s_{\text{Fed},h} \quad (3.7)$$

## Clustering der Fahrstreifenmarkierung

Um die Position des Ego-Fahrzeugs zu bestimmen, werden die detektierten Punkte der Fahrstreifenmarkierungen der Einzelbilder mittels der Kenntnis der Fahrzeugbewegung innerhalb eines Zeitfensters von fünf Sekunden zusammengefasst. Der Ursprung des gemeinsamen lokalen Koordinatensystems liegt dabei im auf die Fahrzeugsymmetrieebene projizierte Vorderrad-Aufstandspunkt zum Startzeitpunkt der Sequenz. Aufbauend auf dieser 2D-Punkte-Repräsentation von Fahrstreifenmarkierungen wird der vorliegende Fahrstreifenverlauf anhand lokaler Gradienten geschätzt. Dabei wird der Gradient für jeden Punkt anhand dessen benachbarter Punkte, die in einem definierten Fenster liegen, siehe Abbildung 3-4 oben links, berechnet. Basierend auf der Approximation des Gradienten mit einem kubischen Spline-Modell mit vier Knotenpunkten<sup>82</sup> sowie dem anschließenden Integrationsschritt wird der Fahrstreifenverlauf angenähert. Für das darauffolgende initiale Clustering wird die minimale Distanz zwischen den Punkten der Fahrstreifenmarkierungen und dem Spline-Modell berechnet.




Abbildung 3-4: Approximation des Fahrstreifenverlauf basierend auf lokalen Gradienten der Fahrstreifenmarkierungen. Oben: Darstellung der Fahrstreifenmarkierungen in x-y-Koordinaten.

<sup>82</sup> Minimal notwendige Anzahl an Stützstellen um den Übergang von einer Linkskurve in eine Rechtskurve mit gegebenenfalls vorhandener Zwischengerade auf dem Intervall von 5 Sekunden darzustellen. Der Übergang an den Knotenpunkten erfolgt stetig differenzierbar.

Unten: Lokale Gradienten der gefensterten Fahrstreifenmarkierungen sowie approximierter Verlauf mittels Spline-Modell

Die drei<sup>83</sup> initialen Cluster-Zentren werden anhand der Maxima im Histogramm des Distanzmaßes extrahiert<sup>84</sup>. Ein Punkt wird zum nächstgelegenen Cluster-Zentrum zugeordnet, sofern er innerhalb einer fest definierten Toleranz von 1,25 m liegt, was etwas weniger als der halben Fahrstreifenbreite entspricht.

Der Verlauf des mit diesem Verfahren identifizierten Clusters mit der größten Anzahl zugeordneter Fahrstreifenmarkierungen wird mit einem kubischen Spline-Modell approximiert und als Referenz für ein zweites Clustering herangezogen. Dieses erfolgt analog zum zuvor beschriebenen Verfahren über die Auswertung der Maxima im Histogramm der Distanz zum Referenzfahrstreifen. Hauptaufgabe des zweiten Clustering Schrittes ist es, die Robustheit gegenüber Fehlern aus der Schätzung des Fahrstreifenverlaufs zu erhöhen sowie potentielle Falschdetektionen zu identifizieren und aus den Daten für die nachfolgenden Berechnungen zu entfernen.

Die finale Zuordnung zu den drei Fahrstreifenmarkierungen:

1. Rechte Fahrstreifenbegrenzung ( $FM_{re}$ ),
2. Mittelmarkierung bzw. Fahrstreifentrennungsmarkierung ( $FM_{mi}$ ),
3. Linke Fahrstreifenbegrenzung ( $FM_{li}$ )

findet anhand der Relation der identifizierten Cluster-Zentren sowie der Fahrzeugposition gemäß des in Abbildung A-3 im Anhang dargestellten Entscheidungsbaums statt.

#### **Regression der Fahrstreifenmarkierungen und Bestimmung der Fahrzeugposition.**

Die gruppierten Fahrstreifenmarkierungen enthalten nach dem Clustering fehlerhafte Punkte aufgrund von Projektionsfehlern und unzureichender Detektion auf Bildebene. Aus diesem Grund werden die drei Fahrstreifenmarkierungen mit einem kubischen Spline-Modell approximiert, welches sowohl die ursprüngliche Entfernung der Detektion zur Kamera als auch deren Intensität, in Form der Helligkeit, berücksichtigt. Das Spline-Modell besitzt dabei wie im vorangegangenen Abschnitt 4 Knotenpunkte um drei Abschnitte unterschiedlicher Krümmung darstellen zu können.

---

<sup>83</sup> Repräsentativ für die zwei äußeren Fahrstreifenmarkierung sowie die ggf. vorhandene Markierung zwischen den beiden Fahrstreifen.

<sup>84</sup> Die für das Clustering in Abbildung 3-4 dazugehörigen Histogramme sind in Abbildung A-4 in Anhang dargestellt.

Die Position des Fahrzeugs in Relation zu den einzelnen Fahrstreifenmarkierungen wird anschließend iterativ durch Ermitteln des minimalen Abstands zwischen der in 2D-Koordinaten transformierten Ego-Fahrzeugposition ( $x_{vh,Mot} \in R^{n \times 2}$ ) und dem fein gesampelten Modell der drei Fahrstreifenmarkierungen  $i$  ( $x_{vh,FM,i} \in R^{n \times 2}$ ) bestimmt.

$$d_{FM,i} = \min(x_{vh,FM,i} - x_{vh,Mot}) \quad (3.8)$$

Aus den Spline-Modellen der Fahrstreifenmarkierungen werden zudem deren Krümmungen an der Ego-Fahrzeugposition abgeleitet.

Das Ergebnis der Fahrzeugpositionsbestimmung für eine exemplarische Versuchsfahrt ist in Abbildung 3-5 dargestellt.

### Bewertung des Verfahrens

Da auf den Versuchsstrecken keine Referenz zur Bewertung der ermittelten Fahrzeugposition innerhalb des Fahrstreifens zur Verfügung steht, lässt sich das Verfahren nur qualitativ bewerten.

Wie in Abbildung 3-5 sichtbar zu erkennen ist, existiert eine hohe Korrelation zwischen den Verläufen der zwei bzw. drei detektierten Fahrstreifenmarkierungen. Da die Verläufe unabhängig voneinander berechnet wurden lässt dies darauf schließen, dass das Verfahren grundsätzlich plausible Ergebnisse liefert. Die Plausibilität der Ergebnisse wird ebenfalls daran bestätigt, dass die Fahrstreifenkrümmung der äußeren bzw. inneren Markierung mit der gefahrenen Krümmung des Versuchsfahrzeugs sehr gut korreliert und auch hinsichtlich der konkret erzielten Werte gut übereinstimmt (Abbildung 3-6).




Abbildung 3-5: Entfernung der Fahrzeugposition zu den drei Fahrstreifenmarkierungen für eine exemplarische Versuchsfahrt der Probandenstudie




Abbildung 3-6: Ermittelte Krümmung der Fahrstreifenmarkierung im Vergleich zu der im Versuch gemessenen gefahrenen Kurvenkrümmung

Einen weiteren Hinweis liefert die Häufigkeitsverteilung der Fahrzeugentfernung zur rechten äußeren Fahrstreifenmarkierung für einen Fahranfänger, der während der Versuchsfahren, subjektiv bewertet, sehr kontrolliert und stets in der Fahrstreifenmitte fuhr. Siehe hierzu Abbildung A-5 im Anhang.

Abbildung 3-5 zeigt, dass insbesondere bei der Bestimmung des Abstands zur äußeren Fahrbahnmarkierung des Nachbarfahrstreifens<sup>85</sup> Fehler auftreten. Es sind immer wieder deutliche Ausschläge zu nicht plausiblen Werten zu erkennen, die außerhalb der 2-fachen Fahrstreifenbreite liegen. Eine Analyse der Daten zeigt, dass diese Fehlberechnungen vorrangig in Rechtskurven mit hohen Rollwinkeln auftreten. Die Fahrbahnmarkierungen sind in diesen Fällen entweder nicht, oder nur noch in sehr geringer Anzahl im Bild bzw. dem ausgewerteten Bildbereich erkennbar.

Zusammenfassend wird aus der Analyse gefolgert, dass die erzielten Ergebnisse und deren Genauigkeiten für eine Bewertung der Fahrerfertigkeiten von ausreichender Qualität sind. Selbst eine Ungenauigkeit der Entfernungsmessung zum Fahrstreifen von 10 cm ist bezogen auf die von erfahrenen Fahrern genutzte Fahrstreifenbreite von bis zu 2 m<sup>86</sup> gerade einmal im Bereich von fünf Prozent.

<sup>85</sup> „Fahrstreifenmarkierung Links“ in den dazugehörigen Abbildungen.

<sup>86</sup> Vgl. Crundall, E. et al.: *Experiential differences across rider groups* (2012), S. 12., siehe auch Abbildung 2-5.



### 3.3 Versuchsstrecke

Zur Entwicklung und Untersuchung der Verfahren zur Beurteilung der Fahrerfertigkeiten wurden Versuchsfahrten mit mehreren Probanden im öffentlichen Straßenverkehr durchgeführt. Die gesamte Teststrecke wurde in zwei Teile unterteilt, beide Abschnitte sind beliebte Motorradstrecken im südhessischen Odenwaldkreis. In Abbildung 3-7 sind die Lage und Aufteilung der beiden Teststrecken A und B markiert. Beide Teststrecken umfassen zusammen 100 unterschiedliche Kurvenfahrten. Die Kennwerte Kurvenkrümmung und Gierwinkeländerung sind in Abbildung 3-8 dargestellt. Die Teststrecke deckt weitläufige Kurven mit Kurvenradien von 500 m ebenso ab wie enge Kurven mit Radien im Bereich bis 30 m. Der Hauptanteil der Kurvenradien befindet sich im Bereich von 50 bis 200 m. Die gesamte Strecke B wurde zusätzlich vor wenigen Jahren neu asphaltiert und besitzt aufgrund der geringen Straßenbreite keine Fahrstreifen-Mittelmarkierung. Im Gegensatz dazu ist die Fahrbahn auf Strecke A bereits länger nicht erneuert worden und weist deutliche Abnutzungserscheinungen und Straßenschäden auf. Auf dem gesamten Streckenabschnitt A ist eine Fahrbahnmittelmarkierung vorhanden.

Aufgrund der unterschiedlichen straßenbaulichen Eigenschaften eignet sich die Gesamtteststrecke daher zum Untersuchen des Einflusses einer Fahrbahn-Mittelmarkierung auf die Linienwahl bzw. das Verhalten unterschiedlich erfahrener Motorradfahrer. Zudem kann die Fahrerfertigausswertung hinsichtlich der Robustheit gegenüber unterschiedlicher Fahrbahnoberflächen und Kurvenradien und Kurvenszenarien überprüft werden.

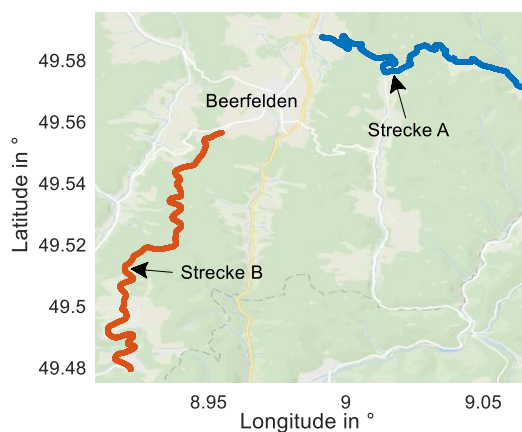


Abbildung 3-7 Visualisierung und Lage der Versuchsstrecken A und B im Odenwald<sup>87</sup>




Abbildung 3-8: Übersicht Kennwerte der Versuchsstrecken

<sup>87</sup> Bildquelle: Google Maps

### 3.4 Probandenkollektiv

Für die Evaluation der entwickelten Methoden zur Auswertung der Fahrfertigkeiten, wurden 19 Probanden akquiriert. Die Probanden stammen großteils aus dem universitären Umfeld, weshalb das Probandenkollektiv nicht für die im realen Straßenverkehr vorgefundene Altersstruktur von Motorradfahrern repräsentativ ist. Nur drei der Fahrer waren zum Zeitpunkt der Studie älter als 29 Jahre, die verbliebenen 16 Teilnehmer sind zwischen 21 und 29 Jahren alt. Bei der Auswahl der Probanden stand die Fahrerfahrung und die Regelmäßigkeit der Nutzung des Fahrzeugs im Vordergrund.

Zur subjektiven Bewertung und Einteilung der Probanden in unterschiedliche Fahrfertigkeitsklassen wurden folgende Kennwerte erhoben:

- Gesamtfahrleistung
  - Fahrleistung im Vorjahr
  - Fahrleistung im Jahr der Versuchsteilnahme
  - Trainingsteilnahmen oder Rennstreckenerfahrung
  - Eigeneinschätzung des Fahrstils
  - Art der Fahrzeugnutzung (Alltag / Spaß / Beruflich)
  - Subjektive Einschätzung durch den Versuchsbetreuer
- } komb. Fahrerfahrung

Im Rahmen der Messdatenauswertung werden die Rollwinkelverteilungen für die einzelnen Fahrer bestimmt, die nach aktuellem Stand der Forschung<sup>88</sup> ein weiteres Maß für die Fahrfertigkeiten ist. Zusätzlich wird aus den Annotationen, die im Rahmen der Erkennung von Fahrfehlern und der Bewertung der Kurvenfahrt erzeugt wurden,<sup>89</sup> der Kennwert der relativen Häufigkeit eines Fahrfehlers für jeden einzelnen Probanden bestimmt. Dieser Kennwert ist definiert durch den Quotienten aus Anzahl gefundener Fahrfehler und Gesamtanzahl der für den Probanden annotierten Kurvenfahrten.

$$p_{\text{Fehler,Prob}} = \frac{N_{\text{Fehler,Prob}}}{N_{\text{Annotation,Prob}}} \quad (3.9)$$

Fahranfänger und Vielfahrer/Experte sind mit den vier Kennwerten, kombinierte Fahrerfahrung, Rollwinkelverteilung, Fehlerhäufigkeit sowie dem subjektiven Eindruck, gut differenzierbar. Dazwischen befindet sich eine Gruppe, die als Normalfahrer klassifiziert wird, womit eine Ordinalskala mit drei Stufen definiert ist. Die Fahrleistung aus dem aktuellen und vergangenen Jahr ermöglicht eine weitere Differenzierung.

<sup>88</sup> Vergleiche Abbildung 2-3

<sup>89</sup> Siehe S. 74 und S. 106

Die Aufteilung erfolgte dann entsprechend in die zwei Gruppen, geübte und ungeübte Normalfahrer. Die Fahrereinteilung sowie deren Kennwerte sind in Tabelle 3-2 dargestellt. Die Einteilung der Probanden liefert nur einen groben Anhaltspunkt für die spätere Untersuchung der Fahrfertigkeiten. Viel Fahrerfahrung als gefahrene Strecke oder auch eine Rollwinkelverteilung, deren Mittelwert im Bereich von 35-40 ° liegt, sind kein eindeutiges Indiz für die Beherrschung und Kontrolle des Fahrzeugs.

Tabelle 3-2: Probandenbewertung und -einteilung

Fahrer	Gesamt Erfahrung in km	Fahrleistung Vorjahr in km	Rollwinkel (Mittelwert Kurven) in °	Fehlerhäufigkeit pro Kurve	Fahrstil	Subjektivbewertung / Sonstiges	
alu	300	0	22	0,6	defensiv		Anfänger
tzi	5.000	300	21	0,5	defensiv		
nme	1.500	1.500	27	0,4	defensiv		
sdr	20.000	1.000	29	0,5	normal		Ungeübt
pma	15.000	100	29	0,3	normal		
jal	12.000	6.000	31	0,3	sportl.	Unfall in Studie	
ija	50.000	-	27	0,4	normal	Amateur Rennfahrerin	Normalfahrer
jdr	75.000	8.000	32	0,4	sportl.	Versuchsbetreuer	
rdr	>100.000	5.000	32	0,5	normal		
dbe	40.000	8.000	36	0,4	sportl.		
sdo	30.000	6.000	28	0,4	normal		
fvi	18.000	5.000	37	0,3	sportl.		
jha	50.000	12.000	32	0,4	sportl.		
sha	100.000	20.000	35	0,5	sportl.		
nma	60.000	5.000	31	0,3	sportl.	Motorradforscher, Studienleiter	Vielfahrer / Experten
hma	>100.000	15.000	27	0,3	normal		
jli	50.000	10.000	35	0,2	sportl.		
rpl	80.000	15.000	34	0,2	sportl.	Motorradforscher	
mko	>100.000	20.000	26	0,1	normal	beruflicher Fahrer	

---

## 4 Segmentierung der Kurvenfahrt

Das folgende Kapitel adressiert die Forschungsfrage:

*Mit welchen Methoden und in welcher Qualität lassen sich beliebige Kurvenfahrten zur Auswertung der Fahrfertigkeiten generalisieren?*

Im ersten Teil des Kapitels wird auf die Motivation und Notwendigkeit der Zerlegung realer Kurvenfahrten in wiederkehrende Segmente eingegangen (Abschnitt 4.1 & 4.2), um herauszustellen, warum Kurvenfahrten generalisiert werden müssen und wie diese Generalisierung dargestellt werden kann.

Darauffolgend werden zur Beantwortung der o.g. Forschungsfrage, Anforderungen an die Manöverzerlegung (Abschnitt 4.3) abgeleitet und Methoden zur Segmentierung und Klassifizierung vorgestellt (Abschnitt 4.4). Anschließend erfolgen Auswertung und Analyse der betrachteten Verfahren mit Fokus auf der erzielbaren Qualität der Zerlegung. Das Kapitel schließt mit einem Zwischenfazit und Ausblick auf zukünftige Optimierungen um die Klassifikationsgüte, die zentrale Grundvoraussetzung für eine erfolgreiche Fahrfertigkeitsauswertung ist, weiter zu verbessern.

### 4.1 Motivation

#### Betrachtung unterschiedlicher Kurvenfahrten im Zeitbereich

Die nach Stand der Technik und Forschung vorgestellten Methoden zur manöverbasierten Auswertung der Fahrerfertigkeiten, basieren auf der Auswertung eines einzigen speziellen und oftmals wiederholt durchgeführten Manövers in einer kontrollierten Versuchsumgebung, wie beispielsweise einem Fahrsimulator. Diese Art der Auswertung eignet sich nicht für die Umsetzung im Fahrzeug, da typischerweise ein Straßensegment, z.B. eine bestimmte Kurve, während eines Fahrzyklus, d.h. einer Fahrt von  $A \rightarrow B$  oder  $A \rightarrow B \rightarrow A$ , nur einmal in derselben Art und Weise befahren wird<sup>90</sup>. Die auftretenden Kurvenfahrten innerhalb eines Fahrzyklus unterscheiden sich hinsichtlich ihrer Parameter wie Krüm-

---

<sup>90</sup> Im Fall  $A \rightarrow B \rightarrow A$  kann jede Kurve theoretisch zweimal befahren werden, dennoch unterscheiden sich die Durchfahrten, da die Kurve jeweils einmal als Rechts als auch als Linkskurve absolviert wird.

mung, Kurvenwinkel etc., was in Abbildung 4-1 und der dazugehörigen Tabelle 4-1 veranschaulicht ist. Die Varianz unterschiedlicher Kurvenfahrten geht aus der bereits gezeigten Versuchsstrecke sowie deren Beschreibung (Abbildung 3-8) ebenfalls hervor.

Kurvenfahrt (a) und (b) sind beide vom Typ Rechtskurve, d.h. auf ein Rollen nach rechts folgt eine stationäre Kurvenfahrt. Anschließend erfolgt ein Rollen nach links in die aufrechte Fahrzeugposition. Es ist erkennbar, dass sich die beiden Kurven insbesondere in der zeitlichen und Bogenlänge unterscheiden. Ein direkter Abgleich der beiden Kurvenfahrten mit einem einzigen Referenzmodell im Zeitbereich ist aufgrund der zeitlichen Variabilität nicht oder nur sehr eingeschränkt möglich.

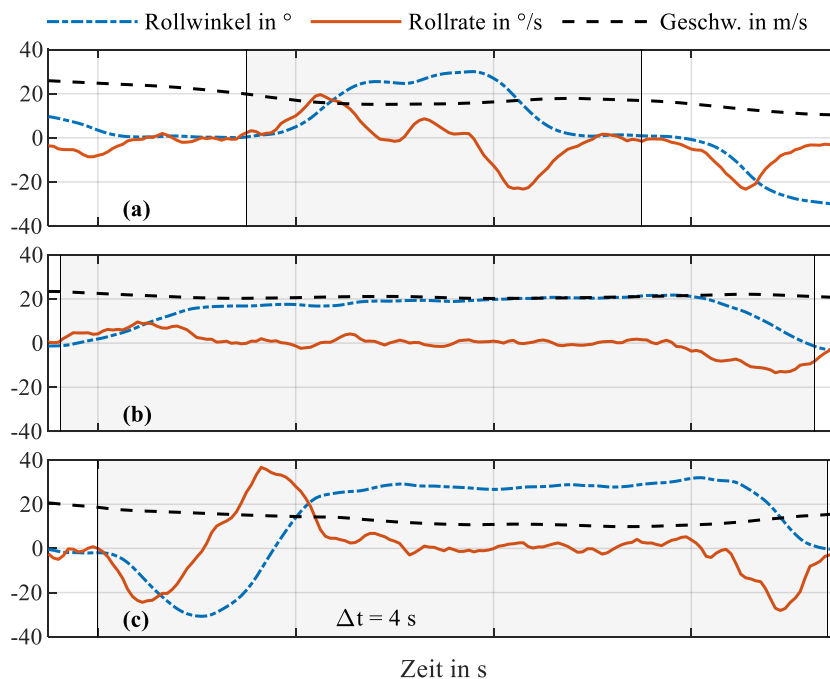


Abbildung 4-1: Messdaten der Fahrzeugdynamik für drei unterschiedliche Kurvenfahrten (grau hinterlegt). (a): 60 ° Kurve, (b): 100 ° Kurve, (c) S-Kurve <sup>91</sup>

Tabelle 4-1: Parameter der Kurvenfahrten in Abbildung 4-1

Manöver	Kurvenkrümmung	Gierwinkel-Änderung	Bogenlänge	Zeit-Dauer
(a): Rechtskurve	-17 /km	60°	120 m	8 s
(b): Rechtskurve	-6.5 /km	100°	350 m	15,5 s
(c): S-Kurve-Teil 1	20 /km	40°	60 m	4 s
Teil 2	-40 /km	220°	150 m	11 s

<sup>91</sup> Magiera, N. et al.: Probabilistic Segmentation into Maneuver Primitives, S. 381.

Die dritte abgebildete Kurvenfahrt (c) zeigt hingegen eine S-Kurve, bei der auf das anfängliche Rollen nach links direkt ein Rollen nach rechts, in eine stationäre Kurvenfahrt erfolgt. Die zeitliche Dauer der Kurvenfahrt (b) und (c) sind nahezu identisch, die unterschiedlichen Zusammensetzungen der Kurvenfahrten (Rollen links/rechts & stationäre Kurvenfahrt) macht die Bewertung der Fahrerfertigkeiten auf Gesamtmanöverebene jedoch wenig erfolgsversprechend.

### **Modellierung als Sequenz von Manöver-Primitiven**

Um die Fertigkeiten des Fahrers in unterschiedlichen Kurvenfahrten bestimmen zu können, ist es daher notwendig, das Gesamtmanöver der Kurvenfahrt in kleinere, aufeinanderfolgende und wiederkehrende Subsequenzen zu unterteilen. Dieses Vorgehen findet sich auch in anderen Forschungsgebieten, die sich mit der Analyse von Zeitreihen beschäftigen, wie z.B. in der Sprach- und Gestenerkennung oder der Robotik wieder. In Anlehnung an die Terminologien für bestimmte Verhaltensmuster, wie z.B. *behavior primitive* in der Biologie oder *sensory-motor primitive* in der Robotik<sup>92</sup>, werden die Subsequenzen innerhalb der Kurvenfahrt als Manöver-Primitive definiert.

---

<sup>92</sup> Vgl. Mataric, M. J.: Sensory-Motor Primitives (2002).

## 4.2 Einordnung der Manöver-Primitive in bestehende Verhaltensmodelle

Gemäß der vorangegangenen Erläuterung bezeichnen die Manöver-Primitive die einzelnen Phasen der Kurvenfahrt, die einer konkreten Handlung oder Regelstrategie des Fahrers zur Bewältigung der Fahraufgabe entsprechen. Diese Definition impliziert eine Zuordnung der Manöver-Primitive zu Führungs- und Stabilisierungsebenen im Drei-Ebenen-Modell nach Donges<sup>93</sup>. Diese Ebenen können gemäß Abbildung 4-2 mit dem Modell von Rasmussen<sup>94</sup>, welches bereits für die Definition von Fahrfertigkeiten genutzt wurde, verknüpft werden<sup>95</sup>. Es wird daher die Hypothese aufgestellt, dass mit dieser Zerlegung in Manöver-Primitive die unterschiedlichen subkortikal ablaufenden Fertigkeiten zur Stabilisierung und Führung des Fahrzeugs bewertbar gemacht werden.

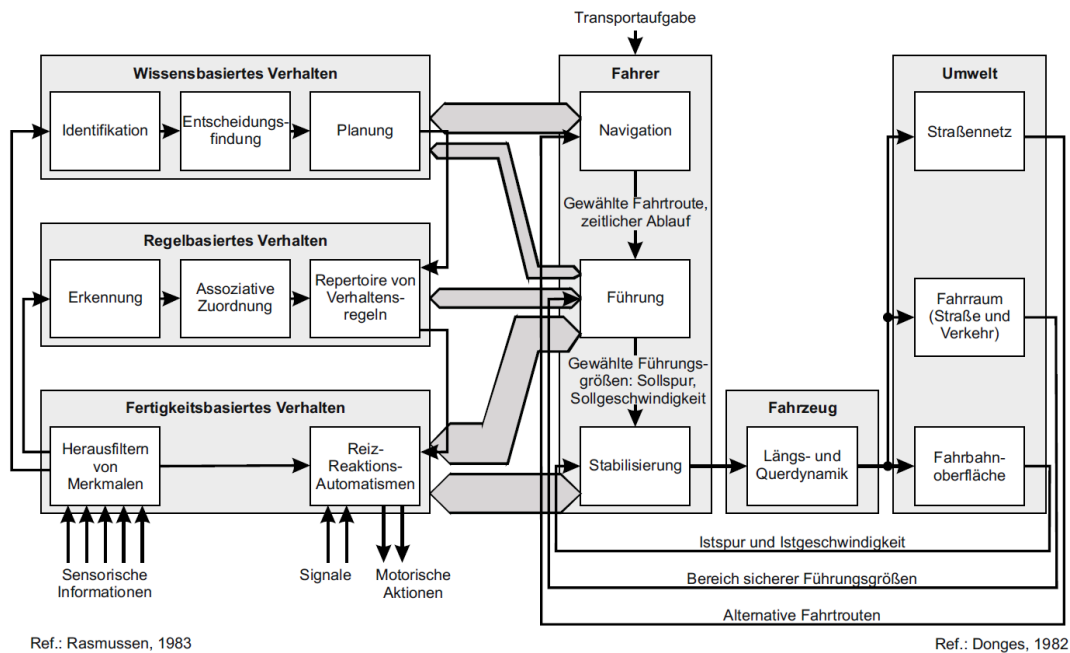


Abbildung 4-2: Drei-Ebenen-Modelle nach Rasmussen und Donges<sup>95</sup>

<sup>93</sup> Donges, E.: Drei-Ebenen Modell der Fahrzeugführung (1982).

<sup>94</sup> Rasmussen, J.: Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models (1983).

<sup>95</sup> Donges, E.: Fahrerverhaltensmodelle (2015), S. 19.

## 4.3 Definition der Manöverzerlegung

### Definition von Kurvenfahrt & Geradeausfahrt auf Manöverebene

Als Kurvenmanöver wird in der folgenden Arbeit eine beliebige Kurvenfahrt in ihrer Gesamtheit bezeichnet. Eine Kurvenfahrt beginnt, wenn das Fahrzeug die vertikale Position mit Rollwinkel  $\varphi \cong 0$  und  $\dot{\varphi} \cong 0$  verlässt, und endet, wenn das Fahrzeug wieder in die vertikale Position mit  $\varphi \cong 0$  und  $\dot{\varphi} \cong 0$  für eine bestimmte Zeitdauer  $t \neq 0$  zurückkehrt. Im Phasendiagramm, dargestellt in Abbildung 4-3, ist das Manöver Kurvenfahrt der gesamte straffierte Bereich außerhalb des weißen Bereichs von Zustands S. Um eine beliebige Motorradfahrt kontinuierlich beschreiben zu können, ist dieser Zustand S als Alternativmanöver notwendig. Die Alternative wird dabei vereinfacht<sup>96</sup> als Geradeausfahrt bezeichnet und ist gekennzeichnet durch geringe Rollwinkel- und Rollraten. Diese Definition lässt beispielsweise leichte Korrekturen der Position innerhalb des Fahrstreifens zu, ohne dass diese als Kurvenfahrt klassifiziert werden.




Abbildung 4-3: Phasendiagramm der Manöver-Primitive<sup>97</sup>

### Definition der Manöver-Primitive

Wie bereits in Abbildung 4-3 erkennbar, sind die Manöver-Primitive durch die Rollrate und den Rollwinkel bei Beginn als auch dem Ende der Rollbewegung definiert. Da die

<sup>96</sup> Auch ein Stillstand des Fahrzeugs in aufrechter, nicht gekippter Position wird als Geradeausfahrt gemäß dieser Definition als Geradeausfahrt klassifiziert obwohl streng genommen keine Vorwärtsgeschwindigkeit und damit keine „Fahrt“ im eigentlichen Sinne stattfindet.

<sup>97</sup> Magiera, N. et al.: Methoden zur Schätzung von Fahrfertigkeiten (2016), S. 9.



Rollrate eine wesentliche Größe zur Klassifizierung ist, wird zwischen stationären und dynamischen Manöver-Primitiven unterschieden. Insgesamt werden drei stationäre und sechs dynamische Manöver-Primitive unterschieden, die in tabellarischer Form in Tabelle B-1 im Anhang aufgelistet sind.

- Das erste stationäre Manöver-Primitiv (S) bezeichnet die Geradeausfahrt als Alternative zu den acht verbliebenen Manöver-Primitiven der Kurvenfahrt. Der Fahrer hat in dieser Phase die Aufgabe das Fahrzeug in der aufrechten Lage zu stabilisieren und die Fahrzeugposition im Fahrstreifen zu regeln. Der Rollwinkel während der Geradeausfahrt schwankt typischerweise um die Nulllage. Die Grenze zur Kurvenfahrt wird bei  $6^\circ$  Rollwinkel gezogen<sup>98</sup>.
- Das zweite (SR) und dritte (SL) Manöver-Primitiv repräsentieren die stationäre Kurvenfahrt in einer Rechts- bzw. Linkskurve. Die Hauptaufgabe des Fahrers in diesem Abschnitt der Kurvenfahrt besteht in der Regelung des Rollwinkels um den zum Kurvenradius und Geschwindigkeit passenden Betriebspunkt. Der Rollwinkel ist vom Betrag her größer als die zuvor angesprochenen  $6^\circ$  Rollwinkel.

Die dynamischen Phasen der Kurvenfahrt sind durch den Fahrer eingeleitete Rollbewegung gekennzeichnet und werden wie folgt definiert:

- Das vierte (RI) und siebte (LI) Manöver-Primitiv beschreiben das Einlenken in eine Kurve aus der Geradeausfahrt heraus. Wie bei stationären Manöver-Primitiven wird zwischen Rechts- und Linkskurve unterschieden. Der Betrag der Rollrate steigt in der ersten Phase bis zu einem Maximalwert (typischerweise größer als  $10^\circ/\text{s}$ ) und sinkt anschließend wieder zurück gegen  $\cong 0^\circ/\text{s}$ . Im gleichen Zuge steigt bzw. sinkt der Rollwinkel auf den für die Kurvenfahrt notwendigen Wert.
- Das sechste (LO) und neunte (RO) Manöver-Primitiv beschreiben den umgekehrten Fall, das Verlassen der Kurve in die Geradeausfahrt. Im Unterschied zum Einlenken sinkt der Absolutwert des Rollwinkel von einem betragsmäßig großen Wert zurück auf  $\cong 0$ .
- Neben dem Ein- und Auslenken in oder aus einer Kurvenfahrt werden zwei Manöver-Primitive definiert, die den Übergang zwischen zwei Kurven unterschiedlicher Richtung definieren (RL & LR). Wie im Phasendiagramm eingezeichnet, ändert sich dabei das Vorzeichen des Rollwinkels, ohne dass der eingezeichnete Bereich der Geradeausfahrt passiert wird. Charakteristisch für diese beiden Manöver-Primitive ist, dass der Absolutwert der Rollrate höhere Werte erreicht als im Fall der übrigen dynamischen Phasen.

---

<sup>98</sup>  $6^\circ$  Rollwinkel entspricht einer Querbeschleunigung von  $1 \text{ m/s}^2$ , die bei Querdynamikbetrachtungen im PKW Bereich typischerweise als Startwert angenommen werden, z.B. bei Auslegung der Lenkmomente.

### Abfolge der Manöver-Primitive

Die gewählte Definition impliziert die logische Abfolge einzelner Manöver-Primitive. Die Zerlegung kann somit als gerichteter Multigraph aufgefasst werden, siehe Abbildung B-1 im Anhang. Der Multigraph ist eine alternative Darstellung zu dem in Abbildung 4-3 gezeigten Phasendiagramm und enthält äquivalente Informationen.

Auf die Geradeausfahrt kann stets nur eines der Manöver-Primitive vier (RI) oder sieben (LI) folgen, da diese den Einlenkvorgang nach rechts bzw. links definieren. Umgekehrt kann in die Geradeausfahrt nur aus den Manöver-Primitiven sechs (LO) oder neun (RO) gewechselt werden, welche den Auslenkvorgang repräsentieren. Der Bereich zwischen Ein- und Auslenken kann hingegen beliebig komplex sein, was an den Mehrfachkanten des Multigraphs innerhalb der beiden gestrichelten Linien erkennbar ist.

Abbildung 4-4 zeigt einen Ausschnitt aus einer Versuchsfahrt mit der in diesem Kapitel vorgestellten Segmentierung. Der ersten Geradeausfahrt folgen zwei Linkskurven, die aus Einlenken und direkt gefolgt dem Auslenken bestehen. Daran schließt sich eine kurze Geradeausfahrt an, gefolgt von einer S-Kurve mit langer stationärer Kurvenfahrt.




Abbildung 4-4: Segmentierung einer exemplarischen Testfahrt mit Links- und S-Kurve

## 4.4 Segmentierungsverfahren

Bei der Auswahl der Methoden zur Segmentierung der Messdaten ist zu beachten, dass die Auswertung der Fahrfertigkeiten retrospektiv nach Abschluss einer einzelnen oder einer Sequenz von mehreren Handlungen erfolgt. Die Segmentierung der Messdaten und die Zuordnung zu den Manöver-Primitiven kann somit mit einem geringen Zeitverzug erfolgen, sodass auch die Historie der Messdaten genutzt und berücksichtigt werden kann.

Für die Umsetzung der Segmentierung von Zeitreihen kann eine Vielzahl an Methoden unterschiedlicher Komplexität verwendet werden, die sich bereits im Bereich der Sprach- und Gestenerkennung etabliert haben. Dies sind Hidden-Markov-Modelle, die eine Son-

derform eines dynamischen Bayes'schen Netzes sind und damit zu der Klasse der probabilistischen Verfahren gehören sowie Rückgekoppelte Neuronale Netze (RNN), die zur Klasse der Künstlichen Neuronalen Netze zugehören.

Im Vergleich zu RNNs besitzen Hidden-Markov-Modelle eine verständliche übersichtliche Struktur mit einer überschaubaren Anzahl an Parametern. Sie eignen sich daher insbesondere zur Anpassung an Probleme, bei denen nur wenige Trainingsdaten vorliegen. Im Gegensatz dazu sind RNNs Black-Box-Modelle mit einer sehr flexiblen Struktur und großen Anzahl an Parametern, wodurch mehr Trainingsdaten zum Lernen eines solchen Modells notwendig sind.

Ein wesentlicher Vorteil beider Verfahren gegenüber einer bspw. deterministischen, schwellwertbasierten Segmentierung wie bei Yoneta ist, dass die Übergänge nicht starr an einen einzelnen Schwellwert gekoppelt sind, sondern die zeitliche Entwicklung der Messung berücksichtigt wird. Der Schwellwert wird somit nicht starr, sondern flexibel bzw. unscharf modelliert. Die genannten Modelle ermöglichen damit robustere Segmentierungsergebnisse für das vorliegende Problem, da der Segmentierungspunkt aufgrund von Messrauschen bzw. den unzähligen im Straßenverkehr auftretenden Faktoren variable ist. Die Verteilung der Segmentierungspunkte über der Rollrate für die in dieser Arbeit verwendeten annotierten Messdaten zeigt diesen Sachverhalt anschaulich in Abbildung B-2 im Anhang. 80 % der Segmentierungspunkte liegen im Bereich von  $-2,5\text{ ‰}$  bis  $+2,5\text{ ‰}$ , jeweils 10 % teilen sich auf die Bereiche ober- und unterhalb davon auf.

Im weiteren Verlauf des Abschnitts werden zwei Verfahren zur Segmentierung der Kurvenfahrt in unterschiedlichen Varianten untersucht, basierend auf Hidden-Markov-Modellen. Bei den Verfahren handelt es sich im ersten Fall um ein rein probabilistisches Modell und im zweiten Fall um eine Kombination aus deterministischer Vorsegmentierung und probabilistischer Klassifizierung. Das Training und die Evaluierung der Modelle und Varianten erfolgt auf Basis eines manuell annotierten Datensatzes, der auf der in Kapitel 3 aufgeführten Teststrecke aufgenommen wurde. Es wird untersucht, welche Messgrößen neben Rollwinkel und Rollrate zur Segmentierung herangezogen werden können und wie sich die Messdatenvorverarbeitung bspw. durch Filterung und Glättung der Signale auf die Performance auswirkt.

#### 4.4.1 Grundlagen

Ein Hidden-Markov-Modell ist allgemein ein probabilistisches Modell für einen Prozess, dessen nicht direkt beobachtbare (engl: *Hidden*) Zustände durch beobachtete Messgrößen sowie dem zeitlich vorangegangenen Zustand modelliert werden. Mit einem solchen Modell kann die zeitliche Reihenfolge von Beobachtungen zur Klassifizierung berücksichtigt werden. Es eignet sich besonders für die Segmentierung und Klassifizierung von Zeitreihen, wie in diesem Fall vorliegend.

## Modellaufbau

Die Parameter  $\lambda$  eines Hidden-Markov-Modells sind wie folgt definiert:

- $\mathbf{A} \in \mathbb{R}^{N \times N}$ : Zustands-Übergangsmatrix. Die Elemente  $\alpha_{i,j}$  beschreiben die Wahrscheinlichkeit des Übergangs eines Zustands  $i$  in den Zustand  $j$ .
- $\mathbf{B} \in \mathbb{R}^{N \times M}$ : Beobachtungsmatrix. Die Elemente  $\beta_{j,k}$  der Beobachtungsmatrix beschreiben die Wahrscheinlichkeit, die Beobachtung der Messgröße  $o_k$  aus dem Zustand  $j$  heraus zu machen, mathematisch formuliert als  $\beta_{j,k} = p(o_k|q_j)$ .
- $\pi \in \mathbb{R}^N$ : Vektor der Anfangswahrscheinlichkeit. Die Elemente  $\pi_i$  beschreiben die Wahrscheinlichkeit, dass die Sequenz initial im Zustand  $i$  startet.

Dabei gilt weiter das  $N$  die Anzahl aller möglichen Zustände bezeichnet sowie  $M$  die Anzahl der Beobachtungen (Messgrößen).  $o$  und  $q$  sind die konkreten Beobachtungen zum Zeitpunkt  $t$  während  $O$  die Beobachtungssequenz und  $Q$  die dahinterstehende Zustandssequenz repräsentiert.<sup>99</sup>

In der aufgeführten Form nehmen die Beobachtungen  $o_k$  diskrete Zustände (0 oder 1) ein. Um kontinuierliche Messdaten in HMM als Beobachtungen zu nutzen, müssen diese mit einem geeigneten Modell in Beobachtungswahrscheinlichkeiten transformiert werden. Hierfür haben sich in der Spracherkennung und anderen Disziplinen Gauß'sche Mischmodelle<sup>100</sup> etabliert, da mit einer Anzahl von  $l$  Mischfunktionen nahezu jede beliebige Verteilung abgebildet werden kann.

Das Mischverteilungsmodell  $\Theta$  wird durch die Parameter beschrieben:

- $\mu \in \mathbb{R}^{n \times m \times l}$ : Mittelwert,
- $\Sigma \in \mathbb{R}^{n \times m \times m \times l}$ : Kovarianzmatrix,
- $w \in \mathbb{R}^{n \times l}$ : Gewichtung.

Es gilt weiterhin, dass  $m$  ist dabei wie im diskreten Fall die Anzahl an Beobachtungen (Messgrößen) zu Zeitpunkt  $t$ .

Anstelle die Wahrscheinlichkeit  $p(o_k|q_j) = \beta_{j,k}$  aus der Beobachtungsmatrix  $\mathbf{B}$  zu verwenden, wird im kontinuierlichen Fall die Wahrscheinlichkeit mittels des Gauß'schen Mischmodells  $\Theta$  berechnet und so  $\mathbf{B}$  ersetzt:

$$p(o|q_j) = p(o|\Theta_j) \quad (4.1)$$

<sup>99</sup> Vgl. Rabiner, L. R.: A Tutorial on HMM (1989), S. 260–261.

<sup>100</sup> Engl.: Gaussian Mixture Model (GMM)

## Parameterschätzung

Die Schätzung der Parameter des Hidden-Markov-Modells mit GMM-Emissionen kann auf zwei unterschiedliche Arten erfolgen, abhängig davon, ob die Trainingsdaten komplett oder nur teilweise annotiert sind.

Im ersten Fall existiert zu jedem Zeitpunkt  $t$  einer Sequenz  $k$  der Länge  $t_{\text{seq}}$  ein Label  $x_{k,t}$  dass einem Hidden State  $q$  entspricht.

Die Übergangswahrscheinlichkeiten  $a_{i,j}$  der Zustands-Übergangsmatrix  $A$  lassen sich dann durch Zählen und anschließend Normieren der Zustandsübergänge berechnen:

$$\alpha_{i,j} = p(q_t = j \mid q_{t-1} = i) = \frac{N_{i,j}}{\sum_i N_{i,j}} \quad (4.2)$$

$$N_{i,j} = \sum_{k=1}^N \sum_{t=1}^{t_{\text{Seq},k}-1} (q_{k,t} = i, q_{k,t+1} = j) \quad (4.3)$$

Die Anfangswahrscheinlichkeit  $\pi_i$  lässt sich ebenfalls mit dem Verfahren des Auszählens bestimmen:

$$\pi_i = p(q_{t=1} = i) = \frac{N_i^1}{\sum_i N_i^1} \quad (4.4)$$

$$N_i^1 = \sum_{k=1}^N (q_{k1} = i) \quad (4.5)$$

Die Parameter  $\Theta = (\mu, \Sigma, w)$  der Mischverteilung werden mittels Expectation-Maximization-(EM)-Algorithmus aus den Beobachtungen  $o(q_t = j)$  geschätzt.<sup>101</sup>

Bei nur teilweiser Annotation sind Label zu diskreten Zeitpunkten  $t$  nicht vorhanden. Es existiert aber eine Zuordnung ganzer Sequenzen zu einer übergeordneten Klasse, wie beispielsweise einem Manöver-Primitiv. In diesem Fall werden die Modellparameter  $\Theta = (A, \pi, \mu, \Sigma, w)$  eines initialisierten Hidden-Markov-Modells mit dem Baum-Welch-Algorithmus im Zuge der Maximierung der Likelihood-Funktion geschätzt und optimiert.<sup>102,103</sup>

---

<sup>101</sup> Murphy, K. P.: Machine learning (2012), S. 350-352.

<sup>102</sup> Vgl. Rabiner, L. R.: A Tutorial on HMM (1989), S. 264–266.

<sup>103</sup> Murphy, K. P.: Machine learning (2012), S. 618–620.

### Berechnung der wahrscheinlichsten Zustandsabfolge

Zur Berechnung der wahrscheinlichsten Abfolge der Hidden States mit einem gegebenen Modell wird der Viterbi-Algorithmus verwendet. Dieses Verfahren der dynamischen Programmierung maximiert die Wahrscheinlichkeit  $P(Q, O|\lambda)$  und findet mittels Backtracking den wahrscheinlichsten Pfad durch die Sequenz. Das Verfahren besteht aus vier Schritten:<sup>104,105</sup>

1. Initialisierung der Verbundwahrscheinlichkeit  $\delta_1(j)$  und der Variable  $\psi_1(j)$ , die den beteiligten Vorgängerzustand abspeichert.

$$\delta_1(j) = \pi_j \beta_j(O_1) \quad 1 \leq j \leq Q \quad (4.6)$$

$$\psi_1(j) = 0$$

2. Rekursion über  $t$  und  $q$

$$\delta_t(j) = \max_{1 \leq i \leq Q} [\delta_{t-1}(i) a_{i,j}] \beta_j(O_t) \quad 2 \leq t \leq t_{\text{Seq}}; \quad 1 \leq j \leq Q; \quad (4.7)$$

$$\psi_t(j) = \operatorname{argmax}_{1 \leq i \leq Q} [\delta_{t-1}(i) a_{i,j}] \quad 2 \leq t \leq t_{\text{Seq}}; \quad 1 \leq j \leq Q; \quad (4.8)$$

3. Terminierung

$$q_{t_{\text{end}}}^* = \operatorname{argmax}_{1 \leq i \leq Q} [\delta_{t_{\text{end}}}(i)] \quad (4.9)$$

4. Pfad-Sequenz mittels Backtracking

$$q_t^* = \psi_{t+1}(q_{t+1}^*) \quad t = t_{\text{Seq}} - 1, t_{\text{Seq}} - 2 \dots 1 \quad (4.10)$$

---

<sup>104</sup> Vgl. Rabiner, L. R.: A Tutorial on HMM (1989), 263f.

<sup>105</sup> Vgl. Murphy, K. P.: Machine learning (2012), 614f. Mit geringfügig anderer Variablen Notation.

### 4.4.2 Hierarchisches Hidden-Markov-Modell

Inspiziert und angelehnt an die Sprach- und Gestenerkennung, bei denen ebenfalls Zeitreihen in einzelne Segmente zerlegt und klassifiziert werden<sup>106</sup>, erfolgt die Segmentierung im ersten Fall mit einem hierarchisch aufgebauten Hidden-Markov-Modell (HMM). Jedes der neun Manöver-Primitive wird dabei mit einem separaten HMM modelliert, die in einem Gesamtmodell miteinander gekoppelt sind.

#### HHMM-Gesamtstruktur

Im Rahmen des vorgeschlagenen Modells werden die neun Manöver-Primitive als Hidden States eines Hidden-Markov-Modells auf Top-Ebene betrachtet. Jedes der neun Manöver-Primitive wird dabei abermals durch ein Hidden-Markov-Modell mit unterschiedlicher Anzahl an Hidden-States auf Modell-Ebene beschrieben. Die Struktur des Modells ist schematisch in Abbildung 4-5 dargestellt. Neben den gezeigten Modellen für die Manöver Primitive Einlenken Linkskurve LI und stationäre Linkskurve SL werden auch die verbliebenen Manöver-Primitive mit einem eigenen HMM modelliert.

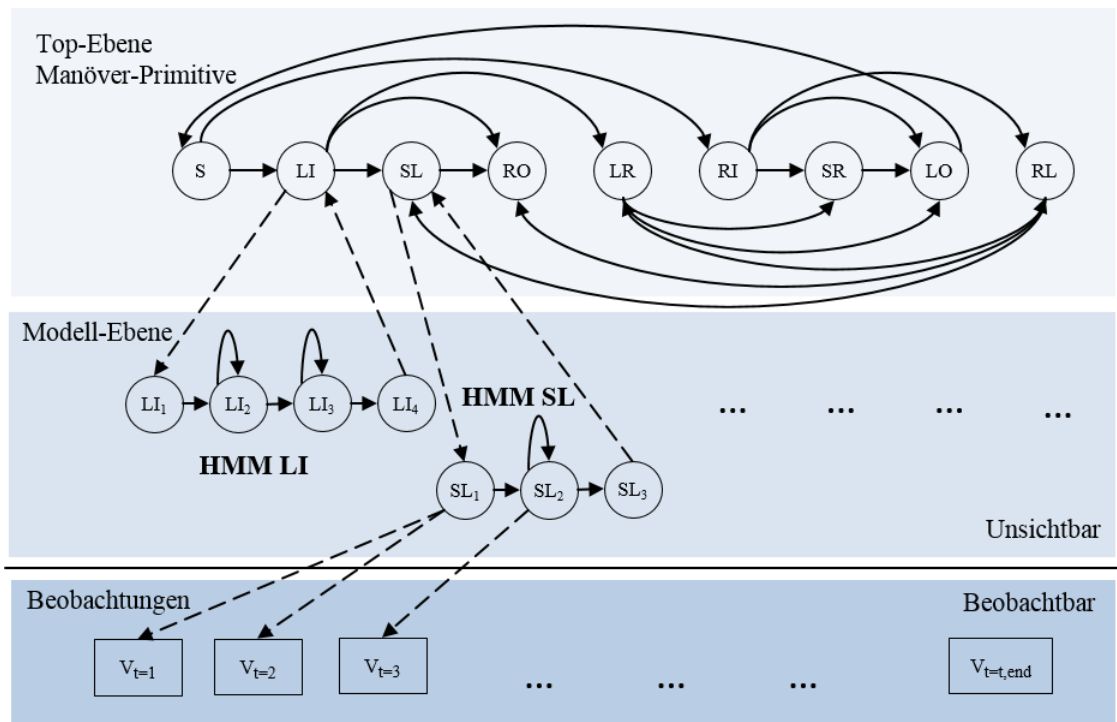


Abbildung 4-5: Modellstruktur des hierarchischem HMM-Ansatzes

<sup>106</sup> Ziel der Spracherkennung ist es beispielsweise, in einem aufgenommenen Zeitsignal eines gesprochenen Satzes die einzelnen Wörter oder Silben zu identifizieren und zu klassifizieren.

### **Sub-Struktur stationärer Manöver-Primitive**

Die drei Manöver-Primitive: Geradeausfahrt, stationäre Rechts- und Linkskurve werden mit einer sequentiellen HMM-Struktur auf Modellebene modelliert. Es sind nur Selbstübergänge sowie ein Übergang in den direkt benachbarten Zustand möglich. Ein Überspringen eines Zustands ist ausgeschlossen.

Die Struktur mit drei Zuständen ist gewählt, um den Start und Endwert der stationären Manöver-Primitive besonderes Gewicht zu verleihen, da diese den Übergang zwischen zwei unterschiedlichen Manöver-Primitiven markieren. Die Segmentierungspunkte sind somit explizit im Modell enthalten. Der zweite Zustand ist für die Phase zwischen dem Start- und Endpunkt notwendig, in der eine gewisse Varianz von Rollwinkel und – rate im Modell zulässig ist.

### **Sub-Struktur transienter Manöver-Primitive**

Die sechs dynamischen Sequenzen, die eine bewusst initiierte Rollbewegung repräsentieren, werden durch ein sequentielles HMM mit 4 Hidden States modelliert. Die Modellierung mit einem weiteren Zustand, gegenüber den stationären Manöver-Primitiven, ist im Signalverlauf der Rollrate in diesen Segmenten begründet. Der zweite und dritte Zustand repräsentieren die Abschnitte der Sequenz, in der die Rollrate ansteigt, bzw. nach dem Erreichen eines Maximalswerts wieder bis auf den Ausgangswert  $\cong 0$  absinkt. Zustand eins und vier dienen auch hier dazu, die Segmentierungspunkte zu markieren bzw. zu gewichten.

Insgesamt besitzt das Modell damit eine Komplexität von 33 Zuständen, wobei der Großteil der Einträge der Zustandsübergangsmatrix aufgrund der sequentiellen Struktur der einzelnen Manöver-Primitive eine Wahrscheinlichkeit von  $p = 0$  besitzen.<sup>107</sup>

### **Segmentierungs-Algorithmus**

Die finale Segmentierung der Messdaten erfolgt über die Berechnung der optimalen Zustandsabfolge mit dem Viterbi-Algorithmus, vorgestellt in Abschnitt 4.4.1 und einer Nachverarbeitung mit einem heuristischen Verfahren zur Plausibilisierung der Segmentdauer der einzelnen Manöver-Primitive. Das hierfür verwendete Verfahren ist in Abschnitt 4.4.4 beschrieben.

---

<sup>107</sup> Die Zustandsübergangsmatrix  $A$  des HHMM ist in Abbildung B-3 in Anhang 2 dargestellt. Aus der Darstellung geht die trotz der 33 Zustände doch recht überschaubare Anzahl an Parametern hervor.



### 4.4.3 Schwellwertbasiertes Hidden-Markov-Modell

Yoneta et al. verwenden zur Detektion von Abbiegemanövern ein simples und robustes schwellwertbasiertes Verfahren. Das Abbiegen beginnt mit Überschreiten und endet mit dem darauffolgenden Unterschreiten eines Schwellwerts für die Gierrate<sup>108</sup>.

Ein solches Verfahren lässt sich grundsätzlich auf die hier vorliegende Problemstellung anwenden, da die Manöver-Primitive über Bereiche im Phasendiagramm von Rollwinkel und Rollrate definiert sind. Dabei liegt der Beginn und das Ende eines jeden Manöver-Primitives gemäß der Definition im Bereich von  $\dot{\varphi} \cong 0^\circ/s$ . Die Segmentierung einer exemplarischen Sequenz anhand eines festen Schwellwerts für die Rollrate ist in Abbildung 4-6 veranschaulicht.

Der Vorteil der schwellwertbasierten Segmentierung ist, dass der Übergang von Manöver-Primitiven nur an deterministisch definierten Punkten geschehen kann. Hieraus ergibt sich im Umkehrschluss allerdings der Nachteil des Verfahrens, dass die Übergänge starr an den jeweiligen Schwellwert gekoppelt sind und die vorangegangene Sequenz nicht berücksichtigt wird. Im konkreten Fall hat dies zur Folge, dass der Beginn des Manöver-Primitives des Einlenkens bspw. zu spät erkannt und zu früh beendet wird, wenn der Schwellwert zu hoch liegt. Umgekehrt kommt es bei einem zu gering gewählten Schwellwert innerhalb der drei stationären Manöver-Primitive Geradeausfahrt, stationäre Rechts- & Linkskurve zu einer Übersegmentierung der eigentlichen Sequenz.




Abbildung 4-6: Exemplarische Darstellung von Übersegmentierung und Falsch-Segmentierung aufgrund schwellwertbasierter Segmentierung

Im Vergleich zu der Erkennung von Abbiegevorgängen ist die Klassifikation der Segmente nach erfolgter Segmentierung deutlich komplexer, weshalb diese abermals mit einem trainierten Hidden-Markov-Modell vorgenommen wird.

<sup>108</sup> Vgl. Yoneta, K. et al.: Offenlegung Motorcycle Rider Assessment Device (2010), S. 26.

## Modell-Struktur

Die Modellstruktur unterscheidet sich im Wesentlichen von der des vorangegangenen Verfahrens darin, dass eine Vorsegmentierung der Daten auf der Messdatenebene stattfindet. Aus den deterministisch segmentierten Abschnitten wird anschließend ein Merkmalsvektor generiert, der als Eingangsgröße für ein Hidden-Markov-Modell auf der Ebene der Manöver-Primitive genutzt wird.

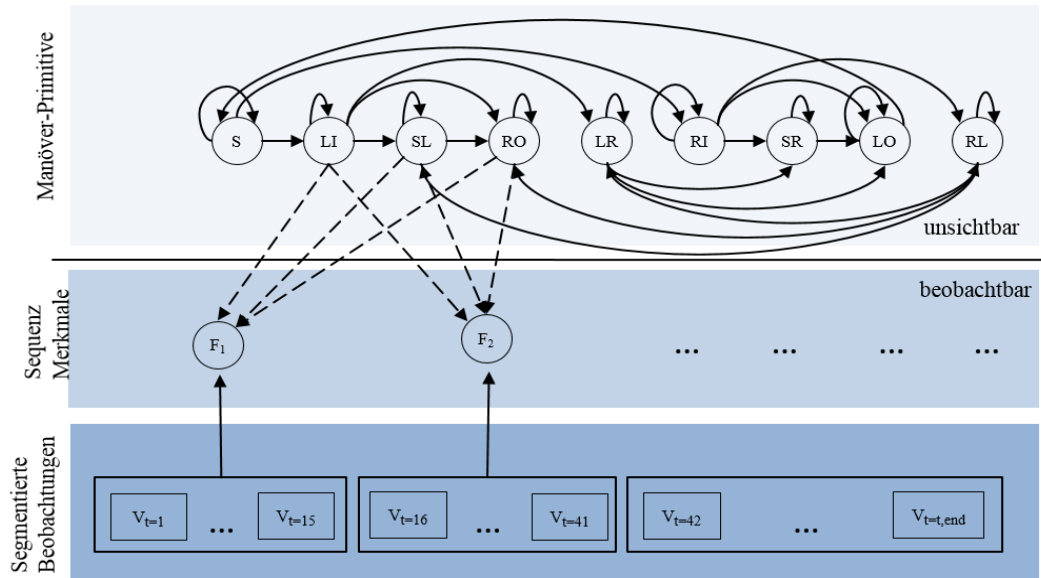


Abbildung 4-7: Modellstruktur des schwellwertbasierten Segmentierungsverfahrens mit HMM Klassifikation

Der Merkmalsvektor  $v = \{\varphi_1, \varphi_{\text{end}}, \dots, \sigma(\dot{\varphi})\}$  setzt sich dabei aus den folgenden Kennwerten des Rollwinkels bzw. der Rollrate zusammen:

### Rollwinkel

- $\varphi_1$ : Rollwinkel zu Beginn der Sequenz
- $\varphi_{\text{end}}$ : Rollwinkel am Ende der Sequenz
- $\bar{\varphi}$ : arithmetisches Mittel des Rollwinkels der Sequenz
- $\sigma_{\varphi}$ : Standardabweichung des Rollwinkels der Sequenz
- $\max \varphi$ : Maximum des Rollwinkels der Sequenz
- $\min \varphi$ : Minimum des Rollwinkels der Sequenz

### Rollrate

- $\max \dot{\varphi}$ : Maximum des Rollwinkels der Sequenz
- $\min \dot{\varphi}$ : Minimum des Rollwinkels der Sequenz
- $\text{range } \dot{\varphi}$ :  $\max \dot{\varphi} - \min \dot{\varphi}$
- $\bar{\dot{\varphi}}$ : arithmetisches Mittel der Rollrate der Sequenz
- $\sigma_{\dot{\varphi}}$ : Standardabweichung des Rollwinkels der Sequenz

## Segmentierungs-Algorithmus

Die Vorsegmentierung erfolgt anhand eines festen Schwellwerts, bei dessen Über- bzw. Unterschreiten, sowohl im positiven als auch negativen Wertebereich, ein neues Segment definiert wird (siehe Abbildung 4-6). Die finale Zuordnung zu den Manöver-Primitiven wird wie beim vorangegangenen Algorithmus durch die Berechnung der wahrscheinlichsten Zustandsabfolge mit dem Viterbi-Algorithmus vorgenommen. Abschließend wird die Zuordnung noch mit der im nachfolgenden Abschnitt beschriebenen Plausibilisierung überprüft und angepasst.

### 4.4.4 Plausibilisierung & Nachverarbeitung

Die mit dem Viterbi-Algorithmus berechnete Zustandsabfolge der Manöver-Primitive ist optimal in Bezug auf das zugrundeliegende Segmentierungsmodell, sowie dessen Parameter. Dies führt in wenigen Fällen dazu, dass Manöver-Primitive mit einer sehr kurzen Zeitdauer erkannt werden, die dem vorangegangenen oder darauffolgenden Abschnitt mit zugeordnet werden müssten. Dabei treten die folgenden anhand Abbildung 4-8 erläuterten Phänomene auf.




Abbildung 4-8: Auftretende Fehlersegmentierungen. ①: Positionsänderung vor der Kurvenfahrt wird als Einlenken klassifiziert, dies hat zur Konsequenz, dass das eigentliche Einlenken als Richtungswechsel interpretiert wird. ②, ③: Positionsänderungen im Anschluss an die Kurvenfahrt werden als Auslenken klassifiziert, was zur Folge hat, dass der eigentliche Auslenkvorgang als Richtungswechsel interpretiert wird.

In selten Fällen wird die dem Einlenkvorgang vorgelagerte Positionsänderung im Fahrstreifen Richtung Kurvenaußenseite – erkennbar in ① – als eigenständige Handlung erkannt (Label-ID 7) und der eigentliche Einlenkvorgang mit ausgeprägtem Rollratenausschlag als Richtungsänderung (Label-ID 5) klassifiziert. In umgekehrter Reihenfolge tritt

das Phänomen am Ende der Kurvenfahrt auf, siehe hierzu Abschnitt ③. Das Aufrichten des Fahrzeugs wird als Richtungsänderung (Label-ID 5) klassifiziert, da eine geringfügige Korrektur vor dem Übergang in die Geradeausfahrt erkannt ist, welche als Auslenken (Label-ID 9) klassifiziert wird. Das Phänomen kann auch am Übergang zwischen zwei Kurvenfahrten auftreten, dargestellt in ② in Abbildung 4-8.

Ein weiteres auftretendes, aber nicht visualisiertes Phänomen ist, dass das Segmentierungsmodell dazu neigt, die Abschnitte und Phasen zwischen zwei Kurvenfahrten als Geradeausfahrt zu klassifizieren, selbst wenn diese nur eine Dauer von wenigen Zehntelsekunden aufweisen.

Die angesprochenen beobachteten Effekte deuten insgesamt darauf hin, dass der Algorithmus innerhalb der Daten mehr Muster erkennen könnte, als durch die neun Manöver-Primitive vorgegeben sind. Im Zuge des Verfahrens zur Bestimmung der Fahrfertigkeiten und der Detektion von Fahrfehlern ist eine solche Segmentierung nicht vorgesehen, da die Auswertung modellbasiert für jedes der Manöver-Primitive stattfindet.

Im Fall des letztgenannten Fehlers, d.h. der Erkennung von sehr kurzen stationären Geradeausfahrten zwischen den Kurven, sind keine negativen Effekte zu erwarten. Für den ersten aufgeführten Fehler ist dies nicht der Fall. Im Optimalfall führt die Vertauschung nur dazu, dass weniger Daten für Einlenkvorgänge vorliegen. Das hat zur Folge, dass mehr Kilometer eingefahren werden müssen, um einen Fahrer erfolgreich zu klassifizieren. Eine weitere negative Folge ist, wenn durch die fehlerhafte Segmentierung falsche Merkmale aus den Segmenten extrahiert werden, die zu einer Falsch-Klassifikation der Fahrerfertigkeiten führen.

Aus diesem Grund erfolgt die Plausibilisierung der Segmentierung mit einem heuristischen Modell, welches die Sequenz aus aktuellem, vorangegangenen und nachfolgendem Manöver-Primitiv, die Zeitdauer der Segmente sowie den dort vorliegenden Rollwinkel nutzt, um letztgenannten Effekte zu beseitigen. Die Heuristik kann anhand des Pseudo-Code in Abbildung B-4 nachvollzogen werden.

## 4.5 Evaluationsmetriken

Zum Vergleich der beiden unterschiedlichen Verfahren sowie deren unterschiedlicher Varianten sind objektive Kennwerte notwendig, die Qualitätsaussagen über die erreichte Segmentierungsgüte zulassen. Grundsätzlich kann die Segmentierung der Zeitreihen als Klassifikationsproblem interpretiert werden, weshalb klassische Verfahren und Metriken zur Bewertung von Klassifikatoren angewendet werden können. Das Problem und damit dessen Lösung kann aus zwei unterschiedlichen Sichtweisen betrachtet werden, wofür sich unterschiedliche Bewertungsverfahren und Metriken ergeben.

Zum einen kann die Übereinstimmung zwischen Label des Algorithmus und der Label-Referenz zu jedem Zeitpunkt  $t$  betrachtet werden, dies wird im Folgenden als zeitliche Konformität bezeichnet.

Die zweite Herangehensweise stellt den eigentlichen Zustandswechsel, also den Übergang von einem Manöver-Primitive in ein abweichendes in den Fokus. Dies hat den Vorteil, dass die tatsächliche Segmentierung sowie deren zeitliche Genauigkeit bewertet wird und das Ergebnis nicht durch lange stationäre Phasen, wie beispielsweise einer Geradeausfahrt verzerrt dargestellt wird.

### 4.5.1 Zeitliche Label-Konformität

Zur Bestimmung der Konformität zwischen Algorithmus und Referenz wird jeder Zeitpunkt als eigenes Klassifikationsereignis betrachtet. Hieraus lässt sich die Konfusionsmatrix (oder. Wahrheitsmatrix)<sup>109</sup>. Die Diagonalelemente der Konfusionsmatrix repräsentieren korrekte Klassifikationsergebnisse, während die Nicht-Diagonalelemente eine Falschklassifikation bedeuten. Aus den Einträgen der Konfusionsmatrix können die Gütemaße einer Klassifikation bestimmt werden. Hier ist insbesondere die Größe der Korrektklassifikationsrate<sup>110</sup> von Bedeutung, da diese die Gesamtheit der positiven<sup>111</sup> Ergebnisse (TP, TN) ins Verhältnis zu den negativen Resultaten (FP, FN) setzt.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.11)$$

---

<sup>109</sup> Engl: *Confusion Matrix*

<sup>110</sup> auch Treffergenauigkeit oder engl.: *Accuracy*,

Abbildung 4-9 zeigt eine exemplarische Konfusionsmatrix. Neben der Korrektklassifikationsrate ist insbesondere von Interesse, wie sich Sensitivität<sup>112</sup> und Positiver Vorhersagewert<sup>113</sup> für die Klassen untereinander verhalten. Hieraus lässt sich schlussfolgern, ob der Algorithmus dazu neigt, einzelne Manöver-Primitive bei der Klassifikation zu bevorzugen. Im gezeigten Fall ist erkennbar, dass die Manöver-Primitive fünf und acht deutlich schlechter klassifiziert werden, als dies für die verbliebenen vier dynamischen Manöver-Primitive der Fall ist.

Ein Nachteil der Auswertung des Klassifikationsergebnisses zu jedem Zeitschritt ist, dass lange stationäre Segmente, d.h. insbesondere die Geradeausfahrt, aber auch zeitlich ausgedehnte stationäre Kurvenfahrten, das Ergebnis verzerren, da deren Anteil, verglichen mit dynamischen Rollbewegungen, wesentlich höher ausfällt. Die Konfusionsmatrix liefert darüber hinaus keinerlei Informationen über die zeitliche Genauigkeit der Segmentierung.

		Referenz-MP (Annotation)									PPV
		MP 1 S	MP 2 SR	MP 3 SL	MP 4 RI	MP 5 LR	MP 6 RO	MP 7 LI	MP 8 RL	MP 9 LO	
Prädiziertes-MP (Algorithmus)	MP 1 S	7272	0	0	75	0	108	75	0	111	0,952
	MP 2 SR	67	3178	34	76	37	0	1	17	82	0,910
	MP 3 SL	40	0	3252	0	32	91	73	10	5	0,928
	MP 4 RI	449	222	0	2619	96	4	8	6	36	0,761
	MP 5 LR	11	39	44	161	1298	215	3	7	3	0,729
	MP 6 RO	281	0	148	9	127	2865	14	3	23	0,826
	MP 7 LI	510	7	181	3	5	35	2867	124	2	0,768
	MP 8 RL	4	28	64	5	6	24	197	1338	0	0,803
	MP 9 LO	301	237	0	8	2	30	7	121	2836	0,801
TPR		0,814	0,856	0,873	0,886	0,81	0,85	0,884	0,823	0,915	ACC: 0,866

Abbildung 4-9: Exemplarische Konfusionsmatrix zur Beurteilung der Segmentierungsergebnisse basierend auf einer erfassten und annotierten Messreihe

<sup>112</sup> Engl: *True positive rate / recall*

<sup>113</sup> Engl: *Precision*

### 4.5.2 Bewertung der Segmentübergänge

Ein zweites Gütemaß zur Bewertung der Segmentierung erhält man, wenn ausschließlich charakteristische Punkte innerhalb einer Zeitreihe ausgewertet werden. Die Idee hierzu stammt von Gensler und Sick, die ihrerseits ein Verfahren benötigten, um die Segmentierung von Mensch und Algorithmus zu vergleichen.<sup>114</sup> Charakteristische Punkte sind im vorliegenden Fall die annotierten Übergänge von einem Manöver-Primitiv in ein zweites abweichendes. Diese werden als Segmentierungs-Zentren bezeichnet, wobei für jedes Segmentierungs-Zentrum eine Segmentierungs-Zone definiert wird, innerhalb dessen eine vom Algorithmus vorgenommene Segmentierung als erfolgreich gewertet wird. Die Segmentierung kann anschließend mit einer Standard 2x2 Konfusionsmatrix für einen binären Klassifikator ausgewertet werden. Das Verfahren ist in Abbildung 4-10 für zwei Segmentübergänge dargestellt.

Ein Segmentübergang wird als True Positive (TP) gewertet, wenn dieser innerhalb der Zone um ein Segmentierungs-Zentrum erfolgt und der Typ des Übergangs, z.B. S  $\rightarrow$  RI, mit dem der Referenz übereinstimmt. Wird ein Übergang außerhalb der Segmentierungszone vorgenommen oder ist vom falschen Typ, wird dieser als False Positive (FP) bewertet. Dabei wird zur detaillierteren Auswertung der erste Fall als FP Typ 2 bezeichnet und ein Übergang des falschen Typs als FP Typ 1.




Abbildung 4-10: Verfahren zur Bewertung der Segmentübergänge nach Gensler und Sick<sup>115</sup>, eigene Darstellung

<sup>114</sup> Gensler, A.; Sick, B.: Criteria to Measure TS Segmentation (2014), S. 194.

<sup>115</sup> Gensler, A.; Sick, B.: Criteria to Measure TS Segmentation (2014).

Wird innerhalb einer Segmentierungszone kein Übergang prädiziert, wird dies als Falsch Negativ (*FN*) gewertet. Um die Konfusionsmatrix zu vervollständigen, werden die Abschnitte zwischen zwei Segmentierungszone ausgewertet. Wird hier kein Segmentübergang gefunden, wird der Abschnitt als True Negative (*TN*) bewertet.<sup>116</sup>

Neben der in Formel (4.11) definierten Korrektklassifikationsrate werden auch die Sensitivität (*TPR*) sowie die Falsch-Positiv-Rate (*FPR*) und der *F1*-Wert (harmonisches Mittel aus Sensitivität und Positivem Vorhersagewert *PPV*) zur Bewertung der Segmentübergänge der verschiedenen Verfahren herangezogen.

Die *TPR* ist hierbei ein Quantitätsmaß für die Vollständigkeit der erzielten Segmentierung, während die *PPV* hier ein Qualitätsmaß dafür ist, wie sehr man dem Ergebnis der Segmentierung vertrauen kann. Der *F1*-Wert verbindet diese beiden Gütemaße miteinander und erlaubt so den Vergleich von Algorithmen, die unterschiedliche Stärken oder Schwächen bei der Erkennungsrate oder der Erkennungsgüte haben.

$$TPR = \frac{TP}{TP + FN} \quad (4.12)$$

$$FPR = \frac{FP}{TP + TN} \quad (4.13)$$

$$PPV = \frac{TP}{TP + FP} \quad (4.14)$$

$$F1 = \frac{2}{\frac{1}{TPR} + \frac{1}{PPV}} \quad (4.15)$$

## Größe der Segmentierungszone

Die Größe der zulässigen Segmentierungszone lässt sich aus der visuellen Annotation menschlicher Probanden ableiten. Die hier getroffene Annahme ist, dass ein Fahrtrainer üblicherweise die Ausführung eines Fahrmanövers, durch einen Motorradfahrer, anhand seiner visuellen Wahrnehmung bewertet. Das impliziert die Unterteilung des Fahrmanövers in unterschiedliche Phasen.

Aus diesem Grund wurde ein Experiment mit fünf Probanden durchgeführt, bei dem die Versuchspersonen rein das Video einer Fahrt auf der Teststrecke mit denen in Unterkapitel 4.3 definierten Manöver-Primitiven annotiert haben. Dabei konnte das Video von den Probanden bildweise vor- und zurückgespult werden.

Die so erzielte Annotation wurde mit der Annotation eines Experten verglichen, dem, zusätzlich zum Video, synchronisierte Messdaten des Rollwinkels und der Rollrate während

---

<sup>116</sup> Vgl. Gensler, A.; Sick, B.: Criteria to Measure TS Segmentation (2014), S. 195.



der Annotation der Daten zur Verfügung standen. Aus dem Vergleich der Experten und Probandenannotationen pro Segmentübergang wird bestimmt, wie groß der Verzug der rein visuellen Erkennung zur messdatenbasierten Erkennung eines Segmentübergangs ist. Daraus lässt sich ableiten, innerhalb welches Intervalls  $t_{\text{ref}} \pm \Delta t$  der Algorithmus um den Referenzpunkt  $t_{\text{ref}}$  segmentieren muss, damit im Verhältnis zum Menschen mindestens gleich viel Information vorhanden bleibt. Die Ergebnisse sind in Abbildung 4-11 dargestellt und zeigen im linken Plot, dass die Sensitivität bis zu  $\Delta t = 0,9$  s linear bei allen Probanden ansteigt, ehe ein Abflachen des Verlaufs erkennbar ist. Bei  $\Delta t = 0,9$  s werden dabei bereits 80 % aller wahren Übergänge erkannt. Die Spezifität, dargestellt im rechten Teil der Abbildung 4-11 deutet daraufhin, dass ab einem  $\Delta t > 0,9$  s weniger TN bzw. mehr FP auftreten. Dies ist darauf zurückzuführen, dass die Intervalle einer Nicht-Segmentierung mit steigender Zonenbreite zunehmend kleiner werden und anfangen sich zu überlappen, womit die Anzahl an TN folglich abnimmt. Eine Evaluation der Segmentierungsergebnisse oberhalb von  $\Delta t > 0,9$  s ist auch aus diesem Grund nicht notwendig.




Abbildung 4-11: Gegenüberstellung visueller Probandensegmentierung und Experten-Referenz zur Bestimmung der zeitlichen Segmentierungszonen-Größe

## 4.6 Ergebnisse

### 4.6.1 Hierarchisches Hidden-Markov-Modell

Die Modelle zur Untersuchung der Varianten der Segmentierung mit einem Hierarchischen Hidden-Markov-Modell (HHMM) sind auf den Datensätzen von zwei Fahrern trainiert, die sich im Rahmen einer Voruntersuchung bezüglich der Kombination der Datensätze als Optimum erwiesen haben. Die vorgestellten Ergebnisse basieren auf der Evaluation der Modelle mit einem Testdatensatz, der von drei weiteren Fahrern stammt.

#### Einfluss der Beobachtungsgrößen

Die Definition der Manöver-Primitive basiert auf Rollwinkel und -rate. Das dazugehörige Segmentierungsmodell, das nur diese beiden Eingangsgrößen verwendet, wird daher als Basis-Modell bezeichnet. Da im Fahrzeug weitere fahrdynamische Kenngrößen zur Verfügung stehen, wird untersucht, inwiefern das Basis-Modell durch Berücksichtigung weiterer Messgrößen verbessert werden kann.

Bei dem ersten zu untersuchenden zusätzlichen Merkmal handelt es sich um die Rollbeschleunigung, d.h. der zeitlichen Ableitung der Rollrate. Diese Messgröße ist von Interesse, da die Rollbeschleunigung ein nochmals schnellerer Indikator für die Änderung der Rollbewegung ist als die Rollrate selbst. Zusätzlich wechselt das Vorzeichen der Rollbeschleunigung im Verlauf der dynamischen Manöver-Primitive, was durch deren Berücksichtigung im Modell abgebildet werden kann.

Von weiterem Interesse ist das Merkmal der gefahrenen Kurvenkrümmung  $\kappa_{\text{Fzg}}$  sowie deren zeitliche Ableitung, da in dieser Messgröße der Rollwinkel  $\varphi_{\text{th}}$  bzw. die Rollrate mit der Fahrzeuggeschwindigkeit  $v_{\text{Fzg},x}$  gekoppelt ist.

$$\kappa_{\text{Fzg}} = \frac{9,81 \cdot \tan \varphi_{\text{th}}}{v_{\text{Fzg},x}^2} \quad (4.16)$$

Ein drittes, Merkmal ist die verstrichene Zeit  $t_{\text{seit } \dot{\varphi}=0}$  seit dem letzten Richtungswechsel<sup>117</sup> bzw. die verbleibende Zeit  $t_{\text{bis } \dot{\varphi}=0}$  bis zum nächsten Richtungswechsel. Die Annahme hinter der Berücksichtigung dieses Merkmals ist, dass Segmentierungspunkte stärker gewichtet werden können und die Abgrenzung von dynamischen Manöver-Primitiven zu stationären Manöver-Primitiven verbessert werden kann.

Die Benennung der Modelle sowie deren Parameter sind in Tabelle 4-2 zusammengefasst.

---

<sup>117</sup> Vorzeichenwechsel der Rollrate  $\dot{\varphi}$ .

Tabelle 4-2: Varianten zur Untersuchung der Beobachtungsgrößen

Name	Beschreibung	Struktur	Messgrößen	Filter
Basis	Basis	HHMM	$\varphi, \dot{\varphi}$	Kein Filter
Var 1	Komplette Rolldynamik	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi}$	Kein Filter
Var 2	Komplette Rolldynamik + verstrichene Zeit	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi}, t_{\text{seit } \dot{\varphi}=0}$	Kein Filter
Var 3	Komplette Rolldynamik + verstrichene Zeit seit Vorzeichenwechsel von $\dot{\varphi}$ + verbleibende Zeit bis Vorzeichenwechsel von $\dot{\varphi}$	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi},$ $t_{\text{seit } \dot{\varphi}=0}, t_{\text{bis } \dot{\varphi}=0}$	Kein Filter
Var 4	Komplette Rolldynamik + verstrichene Zeit seit Vorzeichenwechsel von $\dot{\varphi}$ + verbleibende Zeit bis Vorzeichenwechsel von $\dot{\varphi}$ bei max. 1s Vorausschau.	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi},$ $t_{\text{seit } \dot{\varphi}=0}, t_{\text{bis } \dot{\varphi}=0}$	Kein Filter
Var 5	Komplette Rolldynamik + Kurvenkrümmung	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi}, \kappa_{\text{Fzg}}$	Kein Filter
Var 6	Kurvenkrümmung + Rollrate + Rollbeschleunigung	HHMM	$\dot{\varphi}, \ddot{\varphi}, \kappa_{\text{Fzg}}$	Kein Filter

Abbildung 4-12 zeigt die Sensitivität sowie die Falsch-Positiv-Rate aufgetragen über der Segmentierungszonenbreite von  $\Delta t = 0$  s bis  $\Delta t = 1$  s. Variante vier weist über die gesamte Segmentierungszonenbreite die beste Sensitivität auf und erzielt bei  $\Delta t = 0,4$  s bereits einen Wert von  $TPR = 0,89$ . Die Varianten zwei und drei, welche die verstrichene Zeit berücksichtigen, folgen auf den Plätzen. Dabei ist zu beobachten, dass Variante drei im Bereich von  $\Delta t = 0 - 0,3$  s bis zu fünf Prozentpunkte über Variante zwei liegt, welche nicht die Vorausschauzeit  $t_{\text{bis } \dot{\varphi}=0}$  besitzt. Die Basis-Variante sowie das Modell, das die komplette Rolldynamik berücksichtigt, haben im unteren Bereich von  $\Delta t$  bereits 10 % Rückstand auf das beste Modell.

Auffällig ist, dass die Performance der Modelle mit Berücksichtigung der Kurvenkrümmung auch gegenüber der Basis-Variante abfällt und sich insbesondere im oberen Bereich von  $\Delta t$  der Abstand zu den anderen Modellen vergrößert. Auf der anderen Seite weist Variante fünf die geringste Falsch-Positiv Rate für  $\Delta t > 0,6$  s auf. Insgesamt liegen die Ergebnisse der  $FPR$ , ausgenommen Variante sechs, in einem engen Konfidenzband.




Abbildung 4-12: Vergleich der Segmentierungsgüte verschiedener Varianten des HHMM-Segmentierungsverfahren

Erkennbar ist, dass die Basis-Variante sowie Variante eins bis fünf ein besseres Segmentierungsergebnis erzielen als ein Mensch, der die Fahrt nur anhand des visuellen Sinneskanals unterteilt.

Die gleiche Rangfolge der Varianten zeigt sich bei Auswertung der absoluten Label-Konformität mit dem Maß der Accuracy in Tabelle 4-3. Variante vier erzielt auch hier die besten Ergebnisse und weist gegenüber der Basis-Variante eine 7 % bessere Klassifikationsrate. Auffällig ist daneben, dass Variante sechs weiter abgeschlagen ist und weniger als 50 % der Testdaten korrekt klassifiziert.

Tabelle 4-3: Absolute Label-Konformität für das HHMM-Segmentierungsverfahren

Name	Basis	Var 1	Var 2	Var 3	Var 4	Var 5	Var 6	Var 4.1	Var 4.2	Var 4.3
ACC	0,812	0,822	0,833	0,842	0,852	0,769	0,468	0,853	0,849	0,844
ACC MP 2-9 <sup>118</sup>	0,797	0,819	0,846	0,867	0,869	0,737	0,351	0,868	0,866	0,863

### Einfluss der Signalglättung und -filterung von Rollwinkel & Rollrate

Die Messgrößen wurden zur Auswertung der Fahrerfertigkeiten bereits von 100 Hz auf 10 Hz abwärtsabgetastet, beschrieben in Abschnitt 3.1.2. In diesem Abschnitt wird untersucht, inwiefern eine weitere Signalglättung Einfluss auf die Segmentierungsqualität hat.

<sup>118</sup> Accuracy bei ausschließlicher Betrachtung der Manöver-Primitive 2-9, d.h. bei nicht Berücksichtigung der Geradeausfahrt

Das Filtern der Daten erfolgt mit einem Savitzky-Golay-Filter, einem mathematischen Glättungsfilter. Die Funktionsweise basiert auf der Regression der Daten innerhalb eines Fensters der Breite  $w$  mit einem Polynom der Ordnung  $k$ . Ein wesentlicher Vorteil dieses Filterverfahrens gegenüber anderen Glättungsfiltern wie beispielsweise dem gleitenden Mittelwertfilter oder einem Butterworth-Filter ist, dass durch die lokale Optimierung der Filterkoeffizienten, auf jedem einzelnen Filterfenster, höhere statistische Momente des Ursprungssignals erhalten bleiben. Dies äußert sich darin, dass Maxima und Minima des Signals sowie deren Breite besser erhalten bleiben.

Der Vergleich der in Tabelle 4-4 aufgeführten Varianten mit unterschiedlich starker Glättung<sup>119</sup> zeigt in Abbildung 4-13, dass das unabhängige Filtern der Signale von Rollwinkel, Rollrate und Rollbeschleunigung dazu führt, dass die  $TPR$  im Bereich von  $\Delta t = 0 - 0,2$  s gegenüber der Variante ohne Glättung absinkt. Der Performance-Rückgang in diesem Bereich ist umso größer, je stärker das Signal geglättet wird. Im Gegenzug wird ab  $\Delta t \geq 0,3$  s ein Anstieg der  $TPR$  gegenüber Variante 3 von bis zu einem Prozentpunkt erreicht, wobei gleichzeitig die  $FPR$  absinkt. Der Rückgang der Falsch-Positiv-Rate ist dabei umso größer, je stärker das Signal geglättet wird.

Tabelle 4-4: Varianten zur Untersuchung des Einfluss der Signalglättung

Name	Beschreibung	Struktur	Messgrößen	Filter
Var 4	Komplette Rolldynamik + verstrichene Zeit seit $\dot{\varphi} = 0$ + verbleibende Zeit bis $\dot{\varphi} = 0$ , max. 1 s Vorausschau.	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi}$ , $t_{\text{seit } \dot{\varphi}=0}, t_{\text{bis } \dot{\varphi}=0}$	Kein Filter
Var 4.1	Var4 + Filterung $\varphi, \dot{\varphi}, \ddot{\varphi}$	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi}$ , $t_{\text{seit } \dot{\varphi}=0}, t_{\text{bis } \dot{\varphi}=0}$	Savitzky-Golay $k = 3$ $w = 15$
Var 4.2	Var4 + Filterung $\varphi, \dot{\varphi}, \ddot{\varphi}$	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi}$ , $t_{\text{seit } \dot{\varphi}=0}, t_{\text{bis } \dot{\varphi}=0}$	Savitzky-Golay $k = 3$ $w = 21$
Var 4.3	Var4 + Filterung $\varphi, \dot{\varphi}, \ddot{\varphi}$	HHMM	$\varphi, \dot{\varphi}, \ddot{\varphi}$ , $t_{\text{seit } \dot{\varphi}=0}, t_{\text{bis } \dot{\varphi}=0}$	Savitzky-Golay $k = 3$ $w = 27$

---

<sup>119</sup> Bei konstanter Ordnung der Polynom Regression (hier  $k=3$ ) steigt die Glättung des Signals mit steigender Fensterbreite  $w$  an.




Abbildung 4-13: Einfluss der Signalglättung auf das HHMM-Segmentierungsverfahren

### Zwischenfazit und Diskussion

Die beiden separat dargestellten Bewertungsmetriken zeigen, dass Variante 4.1 zwar hinsichtlich der Sensitivität die höchsten Werte erzielt, die Varianten 4.2 und 4.3 mit stärkerer Filterung eine niedrigere Falsch-Positive Rate aufweisen. Insgesamt erzielt Variante 4.2 die beste Performance, betrachtet man die Kennwerte kombiniert im  $F1$ -Wert bzw. der Accuracy (siehe auch Abbildung 4-15). Damit wird die Hypothese bestätigt, dass die beiden Zusatzmerkmale  $t_{\text{seit } \varphi=0}$  und  $t_{\text{bis } \varphi=0}$  eine für die Segmentierung entscheidende Information enthalten.

Über die Größe  $t_{\text{seit } \varphi=0}$  erhält das Segmentierungsmodell die Möglichkeit, die zeitliche Dauer der unterschiedlichen Manöver-Primitive explizit in Form einer Beobachtungswahrscheinlichkeit zu berücksichtigen. Ohne diese Information ist die Zeitdauer nur implizit und auf abstrakter Ebene in der Zustand-Übergangsmatrix kodiert. Von der Zusatzinformation profitiert insbesondere die Detektion der dynamischen Manöver-Primitive vier bis neun, da deren zeitliche Dauer wesentlich stärker begrenzt ist als die der stationären Manöver-Primitive.

Tabelle 4-5: Klassenspezifische Sensitivität für HHMM verschiedener Varianten

Manöver-Primitive	Klassenspezifische Sensitivität (TPR)								
	MP 1 S	MP 2 SR	MP 3 SL	MP 4 RI	MP 5 LR	MP 6 RO	MP 7 LI	MP 8 RL	MP 9 LO
Var 1	<b>0,829</b>	<b>0,924</b>	0,875	0,767	0,755	0,795	0,791	0,692	0,834
Var 4.1	0,814	0,856	0,873	<b>0,886</b>	<b>0,810</b>	<b>0,850</b>	<b>0,884</b>	0,823	0,915
Var 4.2	0,804	0,860	<b>0,885</b>	0,868	0,803	0,848	0,863	<b>0,851</b>	<b>0,914</b>

Tabelle 4-6: Klassenspezifische Präzision für HHMM verschiedener Varianten

Manöver-Primitive	Klassenspezifische Relevanz (PPV)								
	MP 1 S	MP 2 SR	MP 3 SL	MP 4 RI	MP 5 LR	MP 6 RO	MP 7 LI	MP 8 RL	MP 9 LO
Var 1	0,903	0,855	0,875	0,761	0,663	0,818	0,749	0,704	0,801
Var 4.1	0,952	0,910	<b>0,928</b>	<b>0,761</b>	<b>0,729</b>	<b>0,826</b>	0,768	<b>0,803</b>	0,801
Var 4.2	<b>0,955</b>	<b>0,917</b>	0,918	0,747	0,697	0,819	<b>0,784</b>	0,766	<b>0,804</b>

Diese These wird auch durch die Ergebnisse der Relevanz gestützt: Für die Manöver-Primitive eins bis drei wird eine Verbesserung der *PPV* von 5 % trotz der Verringerung der *TPR* erzielt. Da einem stationären Manöver-Primitiv immer ein dynamisches folgt bzw. vorausgeht, kann diese Verbesserung nur daher zustande kommen, dass vormals Falsch-Positiv-Klassifikationen nun richtigerweise den dynamischen Manöver-Primitiven zugeordnet werden. Dies kann auch anhand der im aufgeführten Konfusionsmatrizen nachvollzogen werden, siehe Tabelle B-2 bis Tabelle B-4 im Anhang.

## 4.6.2 Schwellwertbasiertes Hidden-Markov-Modell

Hauptinfluss auf die Segmentierung mittels schwellwertbasiertem Verfahren hat die Wahl des Schwellwerts, wie in Abbildung 4-6 aufgezeigt. Aus diesem Grund wurde die Variation des Schwellwerts im Bereich von  $\dot{\phi} = 0$  bis  $|\dot{\phi}| = 5$  untersucht. Die Ergebnisse werden anhand Abbildung 4-14 erläutert.




Abbildung 4-14: Einfluss des Schwellwerts der Rollrate auf das S-HMM Segmentierungsverfahren

Im linken Teil der Abbildung ist erkennbar, dass die Variante mit einem Schwellwert bei  $\dot{\varphi} = 1^\circ$  das beste Ergebnis bei der Erkennung von Segmentübergängen erzielt. Bereits ab einem Wert von  $\Delta t = 0,2$  s werden mehr als 85 % der wahren Übergänge erkannt. Die hinsichtlich des Schwellwerts benachbarten Varianten ( $\dot{\varphi} = 0^\circ$  und  $\dot{\varphi} = 2^\circ$ ) erzielen entweder im Bereich unterhalb oder oberhalb von  $\Delta t = 0,2$  s schlechtere Ergebnisse. Ab einem Schwellwert von  $\dot{\varphi} = 3^\circ$  ist mit jedem Grad ein weiterer Performanceabfall zu beobachten.

Ein geringfügig anderes Verhalten zeigt sich bei Betrachtung der Falsch-Positiv-Rate. Hier erzielt die Variante mit  $\dot{\varphi} = 0^\circ$  die geringsten Falsch-Positiv Detektionen. Mit Anstieg des Schwellwerts steigt gleichzeitig auch die *FPR*, wobei die Varianten  $\dot{\varphi} = 1^\circ$  und  $\dot{\varphi} = 2^\circ$  im Bereich  $\Delta t \geq 0,6$  s nahezu identische Ergebnisse erzielen.

Die Ergebnisse des zweiten Bewertungskriteriums weisen ebenfalls darauf hin, dass für das Verfahren mit Vorsegmentierung ein Optimum für einen Schwellwert im Bereich von  $\dot{\varphi} = 1 - 2^\circ$  erzielt wird. Für größere Schwellwerte sinkt sowohl die Accuracy für die Betrachtung aller Manöver-Primitive als auch die Untergruppe der Manöver-Primitive der Kurvenfahrt, siehe Tabelle 4-7.

Tabelle 4-7: Absolute Label-Konformität für SHMM-Segmentierungsverfahren

Name	SHMM $\dot{\varphi} = 0^\circ$	SHMM $\dot{\varphi} = 1^\circ$	SHMM $\dot{\varphi} = 2^\circ$	SHMM $\dot{\varphi} = 3^\circ$	SHMM $\dot{\varphi} = 4^\circ$	SHMM $\dot{\varphi} = 5^\circ$
ACC	0,844	0,851	0,851	0,823	0,804	0,761
ACC MP 2-9	0,850	0,855	0,838	0,797	0,777	0,740

### 4.6.3 Vergleich der Segmentierungsverfahren

Trotz der unterschiedlichen Verfahren werden sehr ähnliche Ergebnisse von beiden Topmodellen der Segmentierungsalgorithmen erzielt. Die Differenz der Accuracy der Label Konformität beträgt 0,2 % zugunsten des HHMM-Verfahrens. Bei dem vorliegenden Testdatensatz entspricht das einen Unterschied von 6,5 s. Dieser Wert dürfte dabei in der Größenordnung der durch die manuelle Annotation verursachten Unsicherheit der Referenz liegen. So ergibt sich bei 1101 Segmentübergängen des Testdatensatz bei einem Annotationsfehler von  $0,1 \text{ s}^{120}$  und einer konservativ geschätzten Auftretenswahrscheinlichkeit von 5 % beispielsweise bereits ein Fehler von 5,5 s auf dem Gesamtdatensatz.

Die Differenz der zeitlichen Bewertung der Segmentübergänge liegt im Bereich von ein bis zwei Prozent. Das SHMM-Verfahren erzielt eine bessere Accuracy im Bereich einer

<sup>120</sup> Kleinstmöglicher Fehler bei gegebener diskreter Abtastrate der Messdaten von 10 Hz.



Segmentierungszonenbreite bis  $\Delta t \leq 0,3$  s, wohingegen das HHMM Verfahren im oberen Bereich überlegen ist. Wird der *F1*-Wert als Kriterium herangezogen, liegen die beiden Verfahren bereits bei einem  $\Delta t = 0,3$  s gleichauf, wobei der Abstand bei  $\Delta t = 0,5$  s bereits zwei Prozentpunkte beträgt. Der im Gegensatz zur Accuracy größer werdende Abstand ist auf die niedrigere FPR des HHMM-Verfahrens zurückzuführen.




Abbildung 4-15: Vergleich der Bewertung der Segmentübergänge für HHMM und SHMM

Ebenfalls von Interesse ist der Vergleich der aufgezeigten Segmentierungs- und Klassifizierungsverfahren mit dem Stand der Technik. Attal et al. untersuchen die Klassifikation von vier definierten Manövern: Geradeausfahrt, Kurvenfahrt rechts, Kurvenfahrt links sowie Kreisverkehr anhand der Messdaten einer Inertialsensorik. Dabei klassifizieren Sie einzelne Sequenzen, die zuvor händisch aus den Messaufnahmen extrahiert wurden. Zur Anwendung kommen neben einem diskreten und einem kontinuierlichen Hidden-Markov-Modell auch weitere Klassifikationsverfahren, wobei das kontinuierliche Hidden-Markov-Modell die besten Ergebnisse erzielte.<sup>121</sup>

Da sich sowohl Trainings- und Testdatensatz sowie die zu klassifizierenden Klassen und Manöver von dem hier verwendeten Datensatz unterscheiden, ist nur ein qualitativer Vergleich möglich. Dafür ist eine Transformation von Manöver-Primitiven zu den von Attal et al. verwendeten Manövern Geradeausfahrt sowie Links- und Rechtskurve notwendig. Hierfür werden die Einträge der Konfusionsmatrix entsprechend zusammengefasst:

- Geradeausfahrt (S): S (MP 1)
- Rechtskurve (RT): RI & SR & LO (MP 4,2,9)
- Linkskurve (LT): LI & SL & RO (MP 7,3,6).
- Andere (O): LR & RL (MP 5,8)

<sup>121</sup> Vgl. Attal, F. et al.: Riding Pattern Recognition for PTW (2013), S. 2034–2035.

Die Manöver-Primitive LR (MP 5) und RL (MP 8) werden, da sie nicht eindeutig einer Rechts- oder Linkskurve zuordenbar sind, weiterhin separat betrachtet und damit bei der Auswertung als Falschklassifikation behandelt. Abbildung 4-16 sowie Tabelle 4-8 zeigen die Ergebnisse des Vergleich mit Attal et. al..

HHMM				SHMM				Attal et al. <sup>122</sup>						
Prädiktion	Referenz			Prädiktion	Referenz			Prädiktion	Referenz					
	S	RT	LT		S	RT	LT		S	RT	LT (+RA)			
	S	95,2	7,8		7,8	S	95,9		6,2	7,5	S	83,9	1,7	0
	RT	2,4	88,7		0,5	RT	2,5		91,2	0,4	RT	4,2	91,5	0
	LT	2,4	0,8		89,0	LT	1,5		1,1	90,0	LT	4,2	3,4	75,0 (89,3)

Abbildung 4-16 Konfusionsmatrizen der Klassifikationsergebnisse auf Manöverebene, Ergebnisse in Prozent

Mit beiden Verfahren werden Ergebnisse erzielt, die qualitativ dem Stand der Technik entsprechen oder ihn sogar im Fall der Erkennung der Geradeausfahrt übertreffen, siehe Abbildung 4-16. Die Auswertung des *F1*-Werts für die drei Manöver führt zur gleichen Schlussfolgerung: Für die Geradeausfahrt werden Werte auf ähnlichem Niveau von 90 % erreicht. Für die beiden Manöver der Kurvenfahrt erzielen die vorgestellten Verfahren geringfügig höhere Werte wie Attal et al. im Fall der Rechtskurve. Ein Vergleich der Ergebnisse für Linkskurven ist nicht zielführend, da diese bei Attal et al. in 14% der Fälle als Kreisverkehr klassifiziert wurden und die Ergebnisse damit nicht direkt vergleichbar sind.

Tabelle 4-8: Gegenüberstellung des klassenspezifischen *F1*-Werts auf Manöverebene

Klasse / Manöver	Klassenspezifischer F1-Wert		
	S	RT	LT
HHMM	0,877	0,918	0,905
SHMM	0,896	0,907	0,911
CHMM Attal <sup>123</sup>	0,908	0,892	0,750

<sup>122</sup> Attal, F. et al.: Riding Pattern Recognition for PTW (2013), S. 2037.

<sup>123</sup> Attal, F. et al.: Riding Pattern Recognition for PTW (2013), S. 2037.

#### 4.6.4 Potential individueller Segmentierungsmodelle

Neben der Untersuchung der verschiedenen Verfahren ist von Interesse, wie die Klassifikationsperformance durch Änderung des Trainingsdatensatzes und damit auch einer fahrerindividuellen Personalisierung verbessert werden kann.

Da das Modell des HHMM-Segmentierungsverfahrens über eine geringe Anzahl an Parametern verfügt wird davon ausgegangen, dass auch bei dem Training auf kleineren, fahrerspezifischen Daten eine ausreichend hohe Generalisierung stattfindet. Basierend auf dieser Annahme wurden fahrerspezifische Modelle nach der Variante 4.1 trainiert und auf den Datensätzen einzelner Fahrer evaluiert.

Die Ergebnisse sind in Tabelle 4-9 aufgelistet. Grau hinterlegte Zellen kennzeichnen den Bestwert auf dem jeweiligen Testdatensatz. Zusätzlich ist das Verbesserungspotential der an den individuellen Fahrstil angepassten Segmentierungsmodelle farblich markiert.

Die Ergebnisse zeigen, dass mit der fahrerabhängigen Individualisierung des Segmentierungsmodells eine Verbesserung von fünf bis acht Prozent erzielt wird. Bei genauerer Analyse fällt auf, dass ein Training auf den Daten von Proband eins oder fünf zu ähnlichen Ergebnissen führt. In beiden Fällen sinken die Erkennungsraten für die Daten von Proband zwei bis vier deutlich gegenüber denen von Proband eins und fünf ab. Zurückzuführen ist dies auf ein ähnliches Fahrverhalten der Fahrer, die beide als Fahranfänger eingeordnet werden. Die zweite Auffälligkeit ist das für den Testdatensatz von Proband zwei die beste Performance mit einem kombinierten Datensatz erzielt wurde und keine Verbesserung der Segmentierungsgüte durch die Anpassung des Modells auf die individuellen Daten beobachtbar ist.

Tabelle 4-9: Fahrerindividuelle Segmentierungsperformance für HHMM-Verfahren mit Modellvariante Var4.1

		Testdaten					
		Prob 1	Prob 2	Prob 3	Prob 4	Prob 5	Alle
Trainingsdaten	Prob 1	0,907	0,774	0,826	0,754	0,867	0,831
	Prob 2	0,837	0,869	0,830	0,821	0,827	0,839
	Prob 3	0,872	0,801	0,910	0,848	0,858	0,855
	Prob 4	0,808	0,816	0,867	0,883	0,801	0,829
	Prob 5	0,898	0,785	0,797	0,769	0,878	0,832
	Prob 2 & 5	0,890	0,871	0,834	0,801	0,856	0,856
	Potential Indv.	+0,017	-0,002	+0,076	+0,082	+0,022	
	Alle	0,882	0,882	0,870	0,828	0,855	0,866
	Potential Indv.	+0,025	-0,013	+0,04	+0,055	+0,023	

## 4.7 Zwischenfazit Manöversegmentierung

In der Analyse verschiedener Kurvenfahrten wurde aufgezeigt, dass für eine standardisierte Auswertung unterschiedlich zusammengesetzter Szenarien eine Zerlegung der Kurvenfahrt in einzelne Bestandteile notwendig ist. Für die Kurvenfahrt wurden daraufhin acht Manöver-Primitive definiert, die wiederkehrenden Handlungen und (Regel-)Strategien des Fahrers entsprechen und sich in das drei Ebenen-Modell der Fahrzeugführung einordnen lassen.

Basierend auf der Definition der Manöver-Primitive wurde ein probabilistisches Verfahren zur Segmentierung der Zeitreihen-Messdaten ausgewählt, dass sich bereits in anderen Disziplinen bewährt hat. Die besondere Eignung eines Hidden-Markov-Modells für die Segmentierungsaufgabe liegt darin begründet, dass die Randbedingung der Abfolge bestimmter Manöver-Primitive direkt im Modell berücksichtigt wird. Bei der Berechnung der Segmentierung wird zudem die Historie der gesehenen Messdaten und nicht nur der aktuelle Zeitpunkt miteinbezogen.

Für das Segmentierungsverfahren wurden zwei unterschiedliche Modellstrukturen erstellt und evaluiert. Dabei zeigt sich, dass ein hierarchisches Hidden-Markov-Modell, welches rein auf den sequentiellen Messdaten beruht und keine Vorverarbeitung benötigt, ebenso gute Ergebnisse erzielt wie ein Hidden-Markov-Modell, das vorsegmentierte Sequenzen über deren statistische Kennwerte klassifiziert. Zum Erzielen der maximalen Segmentierungsgüte, verglichen mit der vom Menschen annotierten Referenz, ist ein weiterer Nachverarbeitungsschritt notwendig. In diesem wird die Zeitdauer eines Manöver-Primitives in Bezug zum Vorgänger und Nachfolger in der Sequenz gesetzt und mittels einer Heuristik bei Bedarf angepasst. Dieser nachträgliche Schritt kann durch Erweiterung des Modells um die explizite Zeitdauer der versteckten Zustände, wie von Yu et al.<sup>124, 125</sup> gezeigt, ersetzt werden. Zudem ist es möglich, nicht nur den vorangegangenen Zustand zur Berechnung der Segmentierung einzubeziehen, sondern ebenfalls dessen Vorgänger.

Für das hierarchische Hidden-Markov-Modell wurde gezeigt, dass das Bereitstellen von zusätzlichen Informationen, wie der vergangenen oder verbleibenden Zeit bis zum Nulldurchgang der Rollrate, die zeitliche Segmentierungsqualität deutlich verbessert und erst so Ergebnisse erzielt werden, die über oder auf gleichem Niveau mit dem Stand der Forschung liegen. Ein Mehrwert gegenüber dem Stand der Forschung wird dadurch erreicht,

---

<sup>124</sup> Shun-Zheng Yu; Kobayashi, H.: An efficient forward-backward algorithm for an explicit-duration hidden Markov model (2003).

<sup>125</sup> Shun-Zheng Yu; Kobayashi, H.: Practical implementation of an efficient forward-backward algorithm for an explicit-duration hidden Markov model (2006).

dass mit dem vorgestellten HHMM-Verfahren keine Vorsegmentierung erforderlich ist und der Segmentierungs- und Klassifikationsprozess in einem Schritt erfolgen.

Für zukünftige Forschungsaktivitäten bleibt die Fragestellung, in welchem Maße die Segmentierung der Motorradkurvenfahrt mit einem tiefen Neuronalen Netz, wie beispielsweise einem Long-Short-Term-Memory Netzwerk, verbessert werden kann. Ebenfalls von Interesse ist, ob die Definition und Realisierung einer noch feineren Segmentierung ermöglicht, weitere Fahrerhandlungen mit Relevanz für die Fahrfertigkeitsklassifikation auszuwerten.

---

## 5 Methoden zur Bewertung der stationären Kurvenfahrt

Aufbauend auf der im vorangegangenen Kapitel 4 definierten Segmentierung der Kurvenfahrt wird im folgenden Abschnitt die Phase der stationären Kurvenfahrt, sowohl für Rechts- als auch für Linkskurven, analysiert. Basierend auf den Daten von exemplarischen Fahrern, denen eindeutig ein Fahrfertigkeitsniveau zuzuordnen ist, werden Modelle zur qualitativen Beschreibung der Ausführung der stationären Kurvenfahrt abgeleitet. Dabei wird angenommen, dass eine Kausalität zwischen Fahrfertigkeit und Ausführungsqualität statistisch vorhanden ist.

### 5.1 Hypothesenbildung

Abbildung 5-1 zeigt die Ausschnitte der stationären Kurvenfahrt in einer Linkskurve<sup>126</sup> von jeweils zwei sehr erfahrenen und unerfahrenen Fahrern.<sup>127</sup> Aufgetragen sind die wesentlichen fahrdynamischen Kenngrößen des Rollwinkels und der Rollrate. Abbildung 5-2 zeigt den Verlauf des Abstands des Vorderradaufstandspunkts zur Fahrbahninnenmarkierung der gleichen Kurvenfahrt und Fahrer.

Bereits beim visuellen Betrachten der Verläufe fällt auf, dass das Signal des Rollwinkels der erfahrenen Fahrer im Vergleich zu den unerfahrenen Fahrern wesentlich glatter ist. Im Signalverlauf der unerfahrenen Fahrer finden sich zudem ausgeprägte Spitzen und Täler wieder, die nicht nur für eine stärker ausgeprägte Regelung, sondern auch für einzelne bewusste Korrekturen sprechen.

Die Regelung bzw. Korrekturen der unerfahrenen Fahranfänger sind daneben mit deutlich größeren Amplituden der Rollrate verbunden, die im dargestellten Fall Werte von 10 °/s übersteigen. Die Regelung der erfahrenen Fahrer kennzeichnet sich durch wesentlich geringe Amplituden im Bereich von 5 °/s und weniger.

---

<sup>126</sup> Das Vorzeichen wurde für die Darstellung umgekehrt, gemäß der Definition in Kapitel 2.1.1 ist der Rollwinkel einer Linkskurve negativ.

<sup>127</sup> Die Einordnung der Fahrer in die Klasse der sehr erfahrenen Fahrer (Abk. „mko“ und „rpl“) ist durch deren Hintergrund als Motorradforscher bzw. als professioneller beruflicher Testfahrer eines großen Motorradherstellers begründet, die unerfahrenen Fahrer (Abk. „alu“ und „nme“) sind beide Fahranfänger mit wenig Fahrerfahrung. Die Fahrereinstufung kann auch in Tabelle 3-2, S. 26 nachvollzogen werden.




Abbildung 5-1 Rollwinkel und Rollrate während stationärer Kurvenfahrt für Fahrer unterschiedlichen Fahrfertigkeitsniveaus

Beim Abstandsverhalten zur Fahrstreifenmarkierung lassen sich ebenfalls Unterschiede zwischen den Fahrern identifizieren. Der erfahrene Fahrer hält sich über die erste Hälfte der Kurvenfahrt am kurvenäußeren Rand auf und hat dementsprechend einen großen Abstand zur Fahrstreifenmarkierung der kurveninneren Seite<sup>128</sup>, erst am Ende der Kurvenfahrt zieht er in die Fahrstreifenmitte. Diese Fahrspurwahl entspricht in Ansätzen der von Spiegel definierten Sicherheitslinie, bei der angestrebt wird, den Kurvenscheitelpunkt zum Kurvenausgang zu verlagern. Dies ermöglicht zum einen die bessere Einsehbarkeit der Kurve, in Linkskurven stärker ausgeprägt als in Rechtskurven, und zum anderen ist Raum zur Erhöhung des Rollwinkels vorhanden, sollten Korrekturen der Fahrlinie notwendig sein.<sup>129</sup>

Bei Fähranfänger 1 ist zu beobachten, dass die Kurve mittig angefahren wird und diese Position durch die Regelung des Rollwinkels (siehe Abbildung 5-1) mit leichten niederfrequenten Schwingungen gehalten wird. Der Bewegung zur Kurveninnenseite wird durch das Absenken des Rollwinkels entgegengewirkt, gefolgt von einer anschließenden Rollwinkelzunahme, um der Bewegung nach außen wieder entgegenzuwirken. Sowohl die Position als auch dessen Verlauf unterscheiden sich von denen des Vielfahrers.

<sup>128</sup> Bei einer Landstraße mit nur einem Fahrstreifen pro Richtung und Rechtsverkehr entspricht das in Linkskurven der Fahrstreifen-Mittellmarkierung, in Rechtskurven der äußeren Fahrstreifenbegrenzungsmarkierung.

<sup>129</sup> Vgl. Spiegel, B.: Die obere Hälfte des Motorrads (2009), S. 74–83.




Abbildung 5-2: Ermittelter Abstand des Vorderradaufstandspunkt zur kurveninneren, hier rechten, Fahrstreifenmarkierung während stationärer Kurvenfahrt für Fahrer unterschiedlichen Fahrfertigkeitsniveaus

## Arbeitshypothesen

Insgesamt sind die folgenden drei Arbeitshypothesen aus den Beobachtungen und dem Stand der Forschung zur Bewertung der Fahrfertigkeiten in der stationären Kurvenfahrt abgeleitet:

### H1: Rollbewegung

*Mit einem Gütemaß für die Welligkeit des Rollwinkel- und Rollratenverlaufs während stationärer Kurvenfahrt können fehlerfreie und fehlerbehaftete Kurvenfahrten unterschieden werden. Folglich können über die Häufigkeitsverteilung des Gütemaßes Fahrer unterschiedlichen Fahrfertigkeitsniveaus unterschieden werden.*

### H2: Fahrfehlerkorrekturen

*Es existieren Subsequenzen innerhalb der stationären Kurvenfahrt, deren Rollwinkel- und Rollratenmuster auf Fahrfehler bzw. deren Korrekturen hinweisen. Die Auftretenshäufigkeit der Detektionen solcher Muster steht im Zusammenhang mit unterschiedlichen Fahrfertigkeitsniveaus.*

### H3: Linienwahl

*Der zeitliche Verlauf der Fahrzeugposition innerhalb der Fahrstreifen begrenzenden Markierungen - bezeichnet als Linienwahl – enthält Merkmale anhand derer sich unterschiedliche Fahrfertigkeitsniveaus unterscheiden lassen.*

## Testdatensatz

Für die Untersuchung der aufgestellten Hypothesen und der damit verbundenen Auswertung, der in den nachfolgenden Unterkapiteln betrachteten Bewertungsverfahren, wurde ein Test- und Trainingsdatensatz erzeugt. Der Testdatensatz umfasst 1491 stationäre Kurvenfahrten, die zur Überprüfung der definierten Hypothesen subjektiv bewertet wurden.



Die Annotation erfolgt anhand der Analyse der Videosequenz der Kurvenfahrt, der Messschriebe des Rollwinkels, der Rollwinkelrate und Geschwindigkeit sowie der ermittelten Position im Fahrstreifen. Bewertet werden die beiden Attribute Regelgüte und Einzelkorrekturen anhand der folgenden Kriterien auf einer Ordinalskala mit drei Rängen:

1. Regelgüte:<sup>130</sup>
  - a. Visuell sichtbare Oszillation der Rollbewegung im Video.
  - b. Amplitude der Rollrateschwingung im Messschrieb.
  - c. Amplitude der Rollwinkelschwingung im Messschrieb.
2. Einzelkorrekturen:
  - a. Plötzliches Auftreten einer visuell im Video sichtbaren Rollwinkeländerung, die unmittelbar aufeinanderfolgend in die entgegengesetzte Richtung auftritt, ohne dass dies durch die Straßengeometrie bedingt ist.
  - b. Amplitude der Rollrate im Messschrieb in der entsprechenden Subsequenz.
  - c. Amplitude der Rollwinkeländerung im Messschrieb in der Subsequenz.

Tabelle 5-1: Ordinalskala Annotation Testdatensatz

Skalenwert:	0	1	2
Beschreibung der Oszillation / Korrektur:	Niedrig / Wenig	Mittel	Hoch / Stark

Eine detailliertere subjektive Bewertung der unterschiedlichsten Kurvenfahrten auf einem höheren Skalenniveau als einer Ordinalskala ist nicht realisierbar. Bisher sind aus dem Stand der Forschung keine Verfahren bekannt, die die Qualität der Ausführung eines Manövers valide kardinalskaliert beschreiben. Die Untersuchung der statistischen Validität der einzelnen Kennwerte bezüglich der Erkennung von Oszillationen und Korrekturen bestätigt diese Vermutung<sup>131</sup>. Es ist denkbar, durch gezielte Berücksichtigung von Randbedingungen, wie dem Fokus auf die gleiche Kurve und dem Paarvergleich, eine höhere Auflösung als die drei gewählten Klassen zu erreichen.

Die Auswahl der annotierten Kurvenfahrten erfolgt nach dem Zufallsprinzip mit der Einschränkung, dass die Mindestdauer der stationären Phase  $\Delta t = 3 \text{ s}$  nicht unterschreitet. Die Zuordnung zu einem Fahrer ist der annotierenden Person während der Annotationsphase nicht bekannt.

---

<sup>130</sup> Vergleiche Abbildung 5-1

<sup>131</sup> Siehe Abschnitt 5.2.1, Abbildung 5-4

## 5.2 Rollbewegung

In diesem Unterkapitel werden die Methoden zur Extraktion von Metriken und Kennwerten zur Untersuchung der aufgestellten Arbeitshypothese, dass sich das Fahrfertigkeitsniveau eines Fahrers durch die Regelgüte der Rollbewegung in stationärer Kurvenfahrt feststellen lässt, vorgestellt.

### 5.2.1 Frequenzbasierte Kennwerte

Hinter der filterbasierten Auswertung der Signale steckt die Hypothese, dass nur ein bestimmter Frequenzbereich der Rollwinkel und Rollratenvariation zur Bestimmung der Fahrerfertigkeiten relevant ist.

Sehr niederfrequente Änderungen des Rollwinkels können beispielsweise ihre Ursache in einer Veränderung der Kurvenkrümmung innerhalb der stationären Kurvenfahrt haben. Auch das Hineinbremsen in die Kurve bzw. das Herausbeschleunigen aus einer Kurve erfordern eine kontinuierliche und damit tendenziell langsame Anpassung des Rollwinkels, welches sich in der Messung einer geringen Rollrate widerspiegelt.

#### Kennwertbestimmung

Um die erläuterten niederfrequente Signalanteile in den auszuwertenden Signale  $\varphi$  und  $\dot{\varphi}$  abzuschwächen, werden die Signale mit einem Butterworth-Hochpassfilter 2. Ordnung gefiltert. Die niedrige Ordnung wurde gewählt, um Artefakte aufgrund von langen Einschwingvorgängen des Filters zu vermeiden. So klingt die Impulsantwort eines Butterworth Hochpassfilters der Ordnung 2 und einer Eckfrequenz innerhalb 0,5 Hz bereits innerhalb einer Sekunde ab.

Da das Signal bereits als abgeschlossene Sequenz vorliegt, wird phasenverzugsfrei gefiltert, d.h. das Filter wird vorwärts wie rückwärts angewandt. Um trotz abgeschlossener Sequenzen und der geringen Filterordnung Artefakte durch den Einschwingvorgang an den Signalenden zu vermeiden, werden die beiden vorangegangenen und nachfolgenden Samples, die nicht der Segmentierung der stationären Kurvenfahrt angehören, mit in die Berechnung einbezogen.

Im zweiten Schritt wird analog zum ersten Schritt ein Butterworth-Tiefpassfilter 2. Ordnung angewandt, um einen Bandpass-Filter zu realisieren. Die Abklingzeit der Impulsantwort des Filters liegt hier bei einer Eckfrequenz von 2 Hz bei ca. 0.6 s. Damit werden auch durch diesen Schritt keine Artefakte für Sequenzen stationärer Kurvenfahrt, die typischerweise länger als 2s andauern, hervorgerufen. Die Impulsantwort des realisierten Bandpassfilters mit den Eckfrequenzen von 0,7 Hz und 2,2 Hz ist in Abbildung C-1 im Anhang dargestellt.

Das Vorgehen<sup>132</sup> entspricht bis zu diesem Punkt insgesamt dem von Yoneta et al..<sup>133</sup>

$$\check{\phi}_{BP}(t) = BP(\phi(t), f_{G,HP}, f_{G,TP}) \quad \text{mit } f_{G,TP} > f_{G,HP} \quad (5.1)$$

$$\check{\phi}_{BP}(t) = BP(\dot{\phi}(t), f_{G,HP}, f_{G,TP}) \quad \text{mit } f_{G,TP} > f_{G,HP} \quad (5.2)$$

Der Tiefpassfilter erfüllt im Gegensatz zum bekannten Verfahren nicht nur den Zweck, hochfrequente irrelevante Störsignalkomponenten mit einer Frequenz von  $f_{G,TP} > 5$  Hz herauszufiltern. Insbesondere im Signal der Rollrate sind Frequenzanteile vorhanden, die durch sportliche Fahrweise zustande kommen. So steigen Amplitude und Frequenz der Änderung der Rollbewegungen bei gleicher absoluter Änderung des Rollwinkels mit zunehmender Sportlichkeit an. Für ein robustes Maß für die Fahrfertigkeit muss genau dieser Fall abgefangen werden, d.h. die entsprechenden Frequenzanteile werden durch den Tiefpassfilter bei der finalen Berechnung des Kennwerts abgeschwächt einbezogen.

Als Kennwert für das frequenzbasierte Verfahren wird die Wurzel des Integrals bzw. der Summe (im diskreten Fall) der quadrierten bandpassgefilterten Signale berechnet.

$$K_{RB,Freq,\phi} = \sqrt{\int_0^{t_{seq}} \check{\phi}_{BP}(t)^2 dt} = \frac{1}{10 \text{ Hz}} \cdot \sqrt{\sum_{i=1}^N \check{\phi}_{BP,i}^2} \quad (5.3)$$

$$K_{RB,Freq,\dot{\phi}} = \sqrt{\int_0^{t_{seq}} \check{\dot{\phi}}_{BP}(t)^2 dt} = \frac{1}{10 \text{ Hz}} \cdot \sqrt{\sum_{i=1}^N \check{\dot{\phi}}_{BP,i}^2} \quad (5.4)$$

## Optimierung der Grenzfrequenzen

Die statistische Validität des Verfahrens und der berechneten Kennwerte wird mit dem doppelten  $t$ -Test geprüft. Dieser prüft die Nullhypothese, ob die Mittelwerte zweier Stichproben der gleichen Grundgesamtheit entstammen. Die alternative Hypothese des Tests lautet, dass die Mittelwerte signifikant voneinander abweichen. Das Ergebnis des  $t$ -Test erlaubt im hier angewendeten Rahmen eine qualitative Aussage, ob sich der Kennwert zur Unterscheidung von fehlerfreien und fehlerbehafteten eignet, zu treffen. Der  $t$ -Wert der Statistik liefert zusätzlich ein quantitatives Maß zur Optimierung der Parameter für

---

<sup>132</sup> Gemeint sind die Abfolge und der Einsatz der mathematischen Operationen. Durch die Segmentierung sind charakteristische Eigenschaften der auszuwertenden Sequenzen jedoch signifikant unterschiedlich.

<sup>133</sup> Yoneta, K. et al.: Offenlegung Motorcycle Rider Assessment Device (2010).

die Kennwertbildung, da er bei gleichbleibenden zu prüfenden Stichproben<sup>134</sup> mit ansteigender Trennschärfe im Betrag steigt. Das Ergebnis der Variation der Grenzfrequenzen für den Kennwert  $K_{RB,Freq,\phi}$  ist in Abbildung 5-3 dargestellt.

Daraus geht hervor, dass die Grenzfrequenz des Hochpassfilters ein lokales Minimum des  $t$ -Werts im Bereich von 0,3 – 0,4 Hz aufweist. Ober- und unterhalb dieses Frequenzbereichs steigt der  $t$ -Wert an und die Kennwertverteilungen sind schlechter voneinander zu unterscheiden. Die Wahl der Grenzfrequenz des Tiefpassfilters hat dagegen einen deutlich geringeren Einfluss auf die Teststatistik. Das lokale Minimum wird hier bei einer Grenzfrequenz von 1,4 – 1,5 Hz erreicht. Die Abbildung zeigt auch, dass bei Grenzfrequenzen oberhalb von 2 Hz, der  $t$ -Wert geringfügig gegenüber dem Optimum absinkt.




Abbildung 5-3: Optimierung der oberen und unteren Grenzfrequenz des Bandpassfilters der frequenzbasierten Auswertung für den Kennwert  $K_{RB,Freq,\phi}$

Für den Kennwert des Rollwinkelsignals  $K_{RB,Freq,\phi}$  ergeben sich analog der beschriebenen Optimierung geringfügig abweichende Grenzfrequenzen von  $f_{G,HP} = 0,6$  Hz und  $f_{G,TP} = 1,5$  Hz.

Weiter wurde bei der Optimierung der Grenzfrequenzen festgestellt, dass ein Aufteilen der Stichproben in zwei Gruppen, Kurvenfahrten mit kurzer und langer zeitlicher Dauer<sup>135</sup>, zu einer vernachlässigbaren Änderung der optimalen Grenzfrequenz für die Teilstichproben führt.

<sup>134</sup> Und damit gleichbleibender Anzahl der Freiheitsgrade der  $t$ -Statistik.

<sup>135</sup> Kurz: 3 bis 6 s, lang: 6 bis 10 s

Die Analyse der Kennwertverteilung zeigt, dass die drei Klassen mit niedriger, mittlerer und hoher Oszillation statistische Unterschiede aufweisen. Dies ist visuell bereits an Abbildung 5-4 erkennbar, die die kumulierte Häufigkeitsverteilung der berechneten Kennwert getrennt nach Ausprägung der Oszillation darstellt. Es zeigt sich, dass die Klassen nur anhand einer ausreichend großen Statistik unterscheidbar sind, da sich die Verteilungen deutlich sichtbar überlappen. Bei einer binären Klassifikation der Oszillation der Rollbewegung mit den gegebenen Kennwerten, bspw. für eine Fahrfehlerdetektion, entstehen damit auch immer Falschklassifikationsergebnisse.

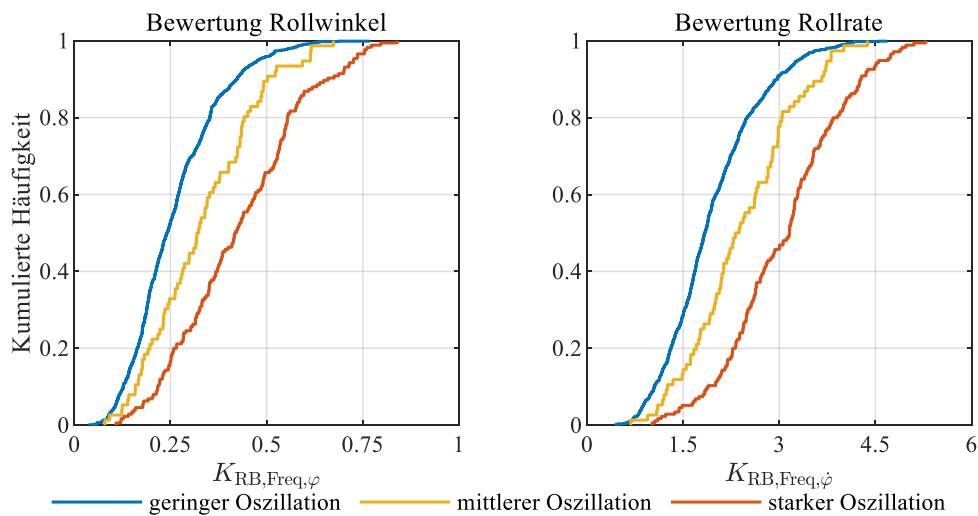


Abbildung 5-4: Kennwertverteilung des frequenzbasierten Verfahrens auf dem nach Oszillationsstärke klassifizierten Testdatensatz

Alternativ können die Grenzfrequenzen hinsichtlich der Fahrer differenzierung optimiert werden. Hierfür wurden die Kennwertverteilungen von Fahrern mit hoher prognostizierter Fahrerfertigkeit mit denen von Fahrern mit wenig Fahrerfahrung ebenfalls mittels  $t$ -Statistik verglichen. Es wird festgestellt, dass sowohl untere als auch obere Grenzfrequenz für beide Kennwerte ansteigen. Die untere Bandpass-Grenzfrequenz sollte im Optimalfall zwischen 0,9 – 1,0 Hz liegen. Die obere Grenzfrequenz verschiebt sich auf gemäß den Ergebnissen der Optimierung auf 2,1 – 2,2 Hz.

Offensichtlich sind zur Unterscheidung der Fahrer die hohen Frequenzanteile von größerer Bedeutung als die der Niederfrequenten, wohingegen dies bei der Erkennung von Fahrfehlern, zu mindestens bei der verfügbaren und untersuchten Stichprobe umgekehrt verhält. Aufgrund der geringen Sensitivität der Ergebnisse gegenüber kleinen Abweichungen der unteren und oberen Grenzfrequenz des Bandpassfilters gegenüber dem Optimum werden Grenzfrequenzen für die Auswertung der Experimente in Unterkapitel 7.3 wie folgt festgelegt:  $f_{G,HP} = 0,7$  Hz und  $f_{G,TP} = 2,2$  Hz. Somit werden niedrigere Frequenzanteile, die zur Erkennung von Fahrfehlern notwendig sind, ebenso berücksichtigt wie höhere Frequenzanteile, die zu einer Steigerung der Differenzierbarkeit von zwei Fahrern unterschiedlicher Fahrerfahrung beitragen.

### 5.2.2 Regressionsbasierte Kennwerte

Die regressionsbasierte Bewertung der Rollbewegung realisiert die Kennwertbildung über die Regression der Messdaten mit einem Spline-Modell. Dabei wird die Modellvorstellung von gutem und weniger gutem Regelverhalten in Form der Modellfreiheitsgrade und durch Definition von Randbedingungen inkludiert.

Im Unterschied zum frequenzbasierten Ansatz muss die Vereinfachung getroffen werden, dass der Kurvenradius im Verlauf der Kurvenfahrt nahezu konstant bleibt oder der Fahrer die Veränderung bereits vorausschauend in seiner Fahrspurplanung für eine „runde“ Linie während der stationären Kurvenfahrt miteinbezieht. „Rund“ wird in diesem Fall für das mathematische Ersatzmodell zur Regression mit der folgenden Randbedingung definiert:

$$\begin{aligned} \dot{\phi}(t_2) &\leq \dot{\phi}(t_1), \quad t_1 < t_2 : \text{Rechtskurven} \\ \dot{\phi}(t_2) &\geq \dot{\phi}(t_1), \quad t_1 < t_2 : \text{Linkskurven} \end{aligned} \quad (5.5)$$

Anschaulich bedeutet dies einen Verlauf wie in Abbildung 5-5 dargestellt. Der Rollwinkel steigt nach dem Einlenkvorgang leicht an, bleibt konstant bevor er zum Ende der stationären Kurvenfahrt, noch vor dem eigentlichen Auslenkvorgang leicht absinkt. Das Regressionsmodell ist bei der gewählten Definition und ausreichend hoher Anzahl an Freiheitsgraden<sup>136</sup> robust gegenüber einer etwaigen Fehlsegmentierung der stationären Kurvenfahrt, da es sich an den Verlauf der Rollrate des vorangegangenen oder nachfolgenden Segments anpassen kann.




Abbildung 5-5: Verlauf einer "runden" Kurve; Approximation des Verlaufes mittels eines linearen Regressionsmodells<sup>137</sup>

<sup>136</sup> Wird durch die Polynomordnung und die Anzahl der Spline-Abschnitte festgelegt.

<sup>137</sup> Magiera, N. et al.: Methoden zur Schätzung von Fahrertigkeiten (2016).

### Kennwertbestimmung:

Das Modell  $S_{RB,\dot{\phi}}$  zur Approximation der Rollrate besteht aus einem kubischen Spline mit drei Knotenpunkten. Jeder der beiden Abschnitte ( $k_1 - k_2, k_2 - k_3$ ) wird mit einem Polynom ( $P_1$  &  $P_2$ ) dritter Ordnung gemäß Formel (5.6) approximiert.

$$P_i(t) = c_{i,1} \cdot t^3 + c_{i,2} \cdot t^2 + c_{i,3} \cdot t + c_{i,4} \quad (5.6)$$

Die beiden Abschnitte bzw. Polynome sind am Knotenpunkt  $k_2$  anhand der Randbedingung der Stetigkeit, Formel (5.7), und Differenzierbarkeit, Formel (5.8) miteinander gekoppelt.

$$P_1(k_2) = P_2(k_2) \quad (5.7)$$

$$P'_1(k_2) = P'_2(k_2) \quad (5.8)$$

Das Modell  $S_{RB,\dot{\phi}}$  besitzt somit sechs freie Parameter. Die Berechnung der Polynomkoeffizienten und Knoten erfolgt mittels Optimierung nach dem Trust-Region-Reflective-Least-Square-Algorithmus<sup>138,139</sup>.

Der Kennwert wird aus der Summe der quadrierten Residuen der Daten der Rollrate und dem Regressionsmodell  $S_{RB,\dot{\phi}}$  berechnet:

$$K_{RB,Reg,\dot{\phi}} = \sqrt{\int_0^{t_{seq}} (\dot{\phi}(t) - S_{RB,\dot{\phi}}(t))^2 dt} \cong \frac{1}{10 \text{ Hz}} \cdot \sqrt{\sum_{i=1}^N (\dot{\phi}_i - S_{RB,\dot{\phi},i})^2} \quad (5.9)$$

Zur Approximation des Rollwinkelverlaufs werden zwei Modelle angewendet, die ermöglichen zwei unterschiedliche aber in beiden Fällen fehlerfreie Kurvenfahrten zu beschreiben.

Das erste Modell  $S_{RB,\dot{\phi},konvex}$  ist über einen kubischen Spline mit vier Knotenpunkten in äquidistantem zeitlichen Abstand realisiert. Die Splines sind über die Bedingungen der Stetigkeit und Differenzierbarkeit an den Knotenpunkten gekoppelt. Die Randbedingung für die Ableitung der Rollrate in Formel (5.5) wird ebenfalls mit eingebunden und hat zur Folge, dass die Approximation des Rollwinkels stets über dem gesamten Verlauf konvex gegenüber der Abszisse gekrümmt ist oder keine Krümmung aufweist.

---

<sup>138</sup> Zur Umsetzung des Modells sowie der Optimierung wurde die SLM Toolbox von John D'Errico für MATLAB sowie MATLAB R2016a inkl. Optimization Toolbox genutzt.

<sup>139</sup> D'Errico, J.: SLM - Shape Language Modeling Toolbox (2017).

Das zweite Modell,  $S_{RB,\varphi,konkav}$  besitzt die gleiche Spline-Struktur mit vier Knotenpunkten und dementsprechend drei Spline-Abschnitten. Bei der Regression wird jedoch die Randbedingung in Formel (5.10) berücksichtigt.

$$\begin{aligned} \dot{\varphi}(t) \leq 0 \quad \& \quad \ddot{\varphi}(t) \geq 0 : \text{Rechtskurven} \\ \dot{\varphi}(t) \geq 0 \quad \& \quad \ddot{\varphi}(t) \leq 0 : \text{Linkskurven} \end{aligned} \quad (5.10)$$

Der Rollwinkelverlauf des Regressionsmodells muss vom Betrag her stets abnehmen, während die Krümmung Null ist oder gegenüber der Abszisse konkav.

Der Kennwert für die Approximation des Rollwinkels wird als Minima der Einzelkennwerte der beiden Teilmodelle definiert.

$$K_{RB,Reg,\varphi,konvex} = \frac{1}{10 \text{ Hz}} \cdot \sqrt{\sum_{i=1}^N (\dot{\varphi}_i - S_{RB,\varphi,konvex,i})^2} \quad (5.11)$$

$$K_{RB,Reg,\varphi,konkav} = \frac{1}{10 \text{ Hz}} \cdot \sqrt{\sum_{i=1}^N (\dot{\varphi}_i - S_{RB,\varphi,konkav,i})^2} \quad (5.12)$$

$$K_{RB,Reg,\varphi} = \min(K_{RB,Reg,\varphi,konvex}, K_{RB,Reg,\varphi,konkav}) \quad (5.13)$$

### Trennschärfe der Rollwinkeloszillationen.

Mit dem regressionsbasierten Kennwert ist die Trennung der drei Manöverausführungen ebenfalls statistisch möglich, wie Abbildung 5-6 links anhand der kumulierten Häufigkeiten zeigt. Im rechten Teil der Abbildung sind zusätzlich die Perzentile der Kennwertverteilungen von Kurvenfahrten mit niedriger und hoher Rollbewegungsschwankung gegeneinander aufgetragen. Der Vergleich des frequenzbasierten und des regressionsbasierten Verfahren zeigt, dass mit Letzterem eine bessere Trennung der unterschiedlich klassifizierten Kurvenfahrten möglich ist: Der Verlauf der blauen Kurve liegt konstant über dem des rot markierten Frequenzkennwerts. Besonders der untere Bereich weist eine erhebliche Verbesserung auf. Über 40 % der Kurvenfahrt mit der Bewertung „niedrig“ liegen außerhalb des Bereichs der „hohen“ Bewertungen. Für den roten Kennwert ist dies nur für 10 % der Bewertungen der Fall. Auch im Bereich zwischen dem 32. und 42. Perzentil heben sich die Kurven noch einmal voneinander.

Im Unterschied zu den frequenzbasierten Kennwerten sind die regressionsbasierten Kennwerte für die Rollrate und den Rollwinkel deutlich weniger korreliert. Der Korrelationskoeffizient für die beiden regressionsbasierten Kennwerte liegt für die Ergebnisse des Testdatensatz bei  $\rho = 0,74$ .



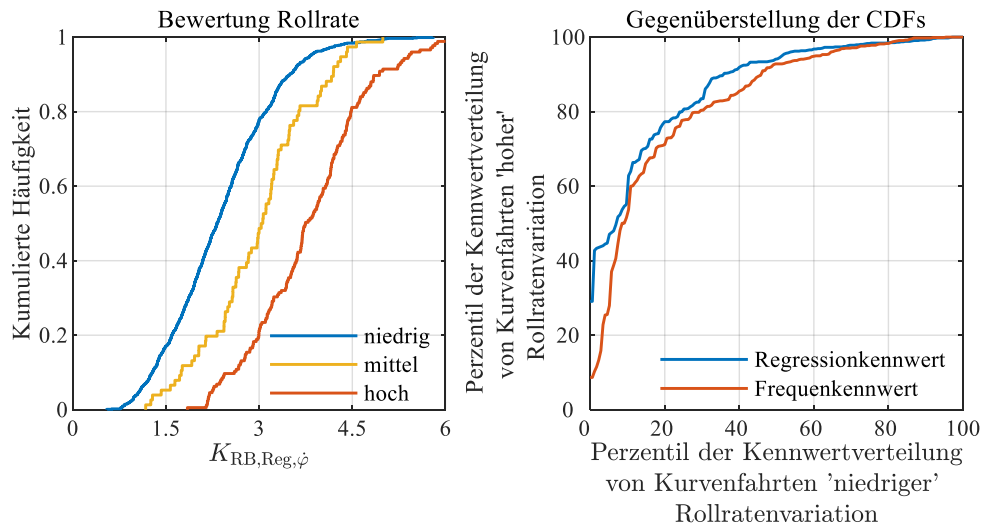


Abbildung 5-6: Bewertung des Testdatensatzes mit regressionsbasiertem Verfahren. Rechts: Gegenüberstellung der Verteilung von Kurvenfahrten mit niedriger bzw. hoher Rollratenvariation

### 5.2.3 Skalierung der Kennwerte

Sowohl für die frequenzbasierten als auch für die mittels Regressionsmodell berechneten Kennwerte wurde eine Korrelationsanalyse zur Identifikation relevanter Einflussfaktoren auf dem Gesamtdatensatz, d.h. nicht nur den Referenzdaten durchgeführt. Dabei wurden mehrere Einflussfaktoren identifiziert, wie Tabelle 5-2 zu entnehmen ist.

Trotz der hohen Varianz der Kennwerte, siehe Abbildung C-3 im Anhang, beträgt der Korrelationskoeffizient für einige Einflussfaktoren  $\rho \geq 0,3$ , sodass von einer mindestens schwachen Abhängigkeit auszugehen ist.

Um die Kennwertberechnung unabhängig von den identifizierten Haupteinflussfaktoren  $l_{\text{Kurve}}$ ,  $\Delta\psi$ ,  $\varphi_{\text{max}}$  sowie  $\bar{\kappa}$  zu machen, wird eine multivariate lineare Regression durchgeführt. Diese liefert die Koeffizienten um die Kennwerte der vier Kennwertverfahren<sup>140</sup>  $i$  entsprechend der Berechnungsvorschrift in Formel (5.14) zu korrigieren. Zusätzlich werden die Kennwerte nach der Korrektur mit einem Faktor normiert, der sich aus der Standardabweichung der korrigierten Kennwerte berechnet, siehe Formel (5.15):

$$K_{\text{RB},i,\text{korr}} = K_{\text{RB},i} - c_{\text{RB},\text{korr},1,i} \cdot \varphi_{\text{max}} - c_{\text{RB},\text{korr},2,i} \cdot \bar{\kappa} - c_{\text{RB},\text{korr},3,i} \cdot l_{\text{Kurve}} - c_{\text{RB},\text{korr},4,i} \cdot \Delta\psi \quad (5.14)$$

$$K_{\text{RB},i,\text{norm}} = \frac{K_{\text{RB},i,\text{korr}}}{c_{\text{RB},\text{korr},5,i}} \quad (5.15)$$

<sup>140</sup> Frequenzbasierte und regressionsbasierte Verfahren für Rollwinkel und Rollrate.

Tabelle 5-2: Korrelationsmatrix von Einflussgrößen<sup>141</sup> und Kennwerten<sup>142</sup> vor Korrektur und Normierung

	$\varphi_{\max}$	$\bar{\kappa}$	$l_{\text{Kurve}}$	$\Delta\psi$	$v_{\min}$	$t_{\text{Kurve}}$	$K_{\text{RB,Freq},\varphi}$	$K_{\text{RB,Freq},\psi}$	$K_{\text{RB,Reg},\varphi}$	$K_{\text{RB,Reg},\psi}$
$\varphi_{\max}$	1,00	0,50	-0,26	0,30	-0,02	-0,33	0,14	0,23	-0,18	0,02
$\bar{\kappa}$		1,00	-0,61	0,46	-0,82	-0,36	-0,18	-0,08	-0,40	-0,29
$l_{\text{Kurve}}$			1,00	0,27	0,56	0,90	0,40	0,31	0,71	0,60
$\Delta\psi$				1,00	-0,38	0,54	0,28	0,30	0,29	0,35
$v_{\min}$					1,00	0,19	0,24	0,19	0,29	0,29
$t_{\text{Kurve}}$						1,00	0,36	0,28	0,71	0,58

Die Parameter können Tabelle C-3 im Anhang entnommen werden. Nach der Skalierung wird keine Korrelation zwischen den Kennwerten und den untersuchten Einflussfaktoren festgestellt, die signifikant größer als  $\rho = 0,1$  ist.

#### 5.2.4 Zwischenfazit zur Arbeitshypothese

Die Kennwerte bzw. deren Verteilungen wurden bisher nur hinsichtlich der Unterscheidung von annotierten Sequenzen unterschiedlich starker Oszillation untersucht, was den ersten Teil der Arbeitshypothese darstellt. Zur Verifikation, dass eine Fahrfertigkeitsunterscheidung anhand der Kennwertverteilungen möglich ist, werden die Verteilungen daher einem statistischen Test unterzogen, der zur Aufgabe hat, die Hypothese zu falsifizieren, dass die Kennwertverteilungen aus derselben Grundverteilung entstammen.

Anhand Abbildung 5-7. ist bereits visuell zu erkennen, dass die Kennwertverteilungen für Linkskurven in drei Gruppen unterscheidbar sind. Normalfahrer und ungeübte Normalfahrer sind hingegen nicht voneinander abgrenzbar.

<sup>141</sup>  $\varphi_{\max}$ : Maximaler Rollwinkel im Kurvensegment,  $\bar{\kappa}$ : Mittlere Kurvenkrümmung,  $l_{\text{Kurve}}$ : Länge der Kurve,  $\Delta\psi$ : Azimuth-Winkel Änderung,  $v_{\min}$ : Minimale Geschwindigkeit,  $t_{\text{Kurve}}$ : Zeitliche Dauer der Kurvenfahrt

<sup>142</sup> Definiert in Unterkapitel 5.2.1 und 5.2.2.

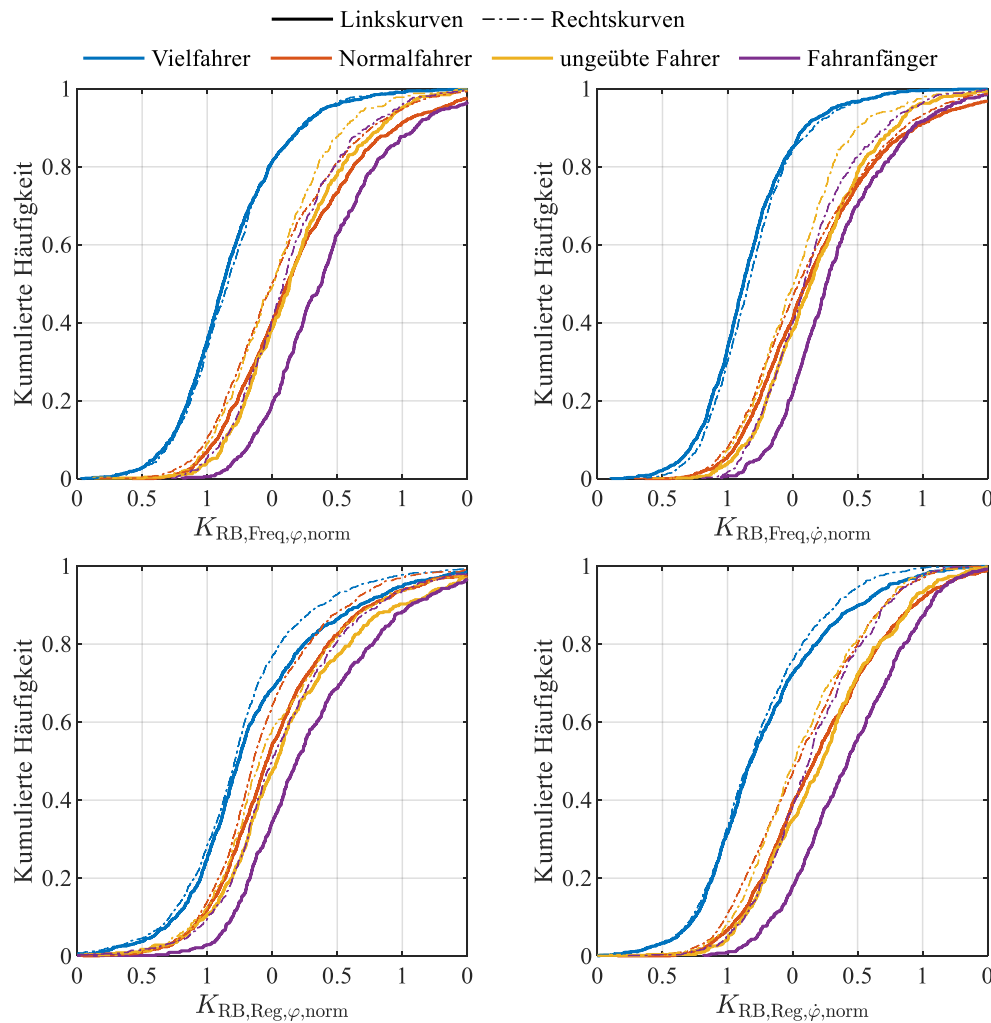


Abbildung 5-7: Kennwertverteilungen der stationären Kurvenfahrt gruppiert nach subjektiven Referenzeinteilung des Fahrfertigkeitsniveaus. In durchgezogen und fett dargestellt: Linkskurven. Gestrichelt und dünn dargestellt: Rechtskurven

Dies wird ebenfalls durch den Zweistichproben  $t$ -Test nachgewiesen, der die Nullhypothese überprüft, dass zwei Stichproben aus unterschiedlichen Normalverteilungen entstammen, siehe hierzu Tabelle C-4 und Tabelle C-5 in Anhang. In Rechtskurven ist bei gegebener Referenzeinordnung der Fahrer auch bei einer Stichprobe von  $N_{\text{Seq}} = 50$  Kurvenfahrten nur eine Unterscheidung von Vielfahrern zu allen drei weiteren Gruppen möglich. Normalfahrer bis hin zu Fahranfängern sind nicht mit einer vertretbaren Irrtumswahrscheinlichkeit anhand der einzelnen Kennwertverteilungen trennbar.

Die Arbeitshypothese hat damit weiterhin bestand:

*Mit einem Gütemaßes für die Welligkeit des Rollwinkel- und Rollratenverlaufs während stationärer Kurvenfahrt können fehlerfreie und fehlerbehaftete Kurvenfahrten unterschieden werden. Folglich können über die Häufigkeitsverteilung des Gütemaßes Fahrer unterschiedlichen Fahrfertigkeitsniveaus unterschieden werden.*

Durch die nachgewiesenen Unterschiede für Linkskurvenfahrten, und eingeschränkt auch für Rechtskurvenfahrten, wird sie nicht falsifiziert. Anhand der Ergebnisse wird weiter geschlussfolgert, dass die Kennwerte nicht einzeln, sondern im Verbund für eine Fahrerklassifizierung betrachtet werden sollten, da nur eine Korrelation in der Größenordnung von 70 % festgestellt ist.

Ebenfalls ist die Einteilung der Fahrergruppen anhand der Kilometerleistung kritisch zu betrachten, da Normalfahrer und ungeübte Normalfahrer nicht bzw. nur bei einer großen Stichprobe an Kurvenfahrten unterschieden werden können. Die Fragestellung der Fahrerindividuellen Klassifizierung sowie der dafür benötigten Daten sollte aus diesem Grund losgelöst von der zuvor getroffenen Einteilung erfolgen und diese ggf. nur als grobe Orientierung berücksichtigen.

## 5.3 Fahrfehlerkorrekturen

Die bisherig vorgestellten Verfahren zur Bewertung der Regelgüte basieren auf der integralen Betrachtung der stationären Kurvenfahrt als Ganzes. Die in diesem Unterkapitel vorgestellte Alternative beruht auf der Annahme, dass innerhalb der stationären Kurvenfahrt kürzere zeitliche Handlungen auftreten, die auf Korrekturverhalten oder unzureichende Beherrschung der Fahrzeugdynamik zurückzuführen sind und als Fahrfehler bezeichnet werden. Die aus dem Fahrfehler resultierenden Muster gilt es in den Messdaten zu detektieren und zu bewerten, um die zweite Arbeitshypothese, dass die Auftretenswahrscheinlichkeit solcher Muster eine Fahrerunterscheidung und Fahrfertigkeitsklassifikation zulässt, zu untersuchen.

### 5.3.1 Ursache und Muster von Fahrfehlern

Bei der Analyse der Messdaten sind zwei Muster identifiziert die wiederholt, unabhängig vom Fahrer auftreten: Ein kurzzeitiger betragsmäßiger Rollwinkelabbau und umgekehrt ein Rollwinkelaufbau von ebenfalls kurzer Dauer.

Der kurzzeitige Rollwinkelabbau ist gekennzeichnet durch einen schnellen Abbau des Rollwinkels in Höhe von mindestens  $5^\circ$  und einer direkt darauffolgenden Erhöhung des Rollwinkels auf den Ausgangswert oder Werte darüber. Zurückzuführen ist dieses Muster auf eine deutliche Lateralbewegung des Fahrzeugs innerhalb des Fahrstreifens. Ohne Korrektur würde das Fahrzeug dabei den Fahrstreifen noch innerhalb der Kurve kurveninnen verlassen. Zu erkennen ist dies beispielhaft im Graphen des lateralen Abstands in Abbildung 5-8. Die Korrektur führt zum Abflachen des Gradienten des lateralen Abstands gegenüber der Fortsetzung des Verlaufs zum Zeitpunkt vor der Korrektur, dargestellt durch die gestrichelte Linie.




Abbildung 5-8: Exemplarische Fahrfehlerkorrektur nach außen

Häufige Ursache für dieses Muster ist ein der eigenen lateralen Position und Fahrtrichtung sowie der vorausliegenden Straßentrajektorie nicht angepasster Lenkimpuls, der in einem zu großen Rollwinkelaufbau endet. Weiterhin kann das Muster in einer unzureichenden Trajektorien-Planung und zu geringen Vorausschau begründet sein, denn bei einer entsprechenden Verlagerung des anvisierten Kurvenscheitelpunkts Richtung Kurvenausgang ist eine solche Korrektur nicht notwendig.

Das zweite Muster, der Rollwinkelaufbau, verläuft analog, nur mit umgekehrtem Vorzeichen. Zuerst erfolgt eine Rollwinkelerhöhung, die über die normalen Schwankungen im Rahmen der Rollwinkelregelung hinausgeht. Nach erfolgter Linienkorrektur wird der Rollwinkel um die gleiche Größenordnung abgesenkt. Anschaulich wird dies an Abbildung 5-9, da vor und nach der Korrektur ein ähnlicher Rollwinkel mit etwa gleichem Gradient vorhanden ist.

Ursächlich für diese Art von Korrektur kann ein zu frühes oder zu zögerliches Einlenken sein oder ein unangepasster zeitlicher Rollwinkelverlauf für den gegebenen geometrischen Straßenverlauf. Ein solcher Verlauf ist gemäß Spiegel bspw. auch durch das Anfahren auf der Kurveninnenseite, anstelle der empfohlenen<sup>143</sup> Kurvenaußenseite begründbar.




Abbildung 5-9: Exemplarische Fahrfehlerkorrektur nach innen

Zum Training des Klassifikationsmodells zur Erkennung von Fahrfehlerkorrekturen wurde der in Abschnitt 5.1 beschriebene Datensatz um detaillierte Annotationen für einzelnen fehlerhaften Subsequenzen ergänzt, in Abbildung 5-8 und Abbildung 5-9 grau hervorgehoben. Annotiert wurde anhand der vorliegenden Video- als auch Fahrdynamik-Messdaten.<sup>144</sup>

<sup>143</sup> Vgl. Spiegel, B.: Die obere Hälfte des Motorrads (2009), S. 74–82.

<sup>144</sup> Neben Intertialmessdaten wurden Lenkwinkel und -moment zur Analyse und Annotation herangezogen.

### 5.3.2 Fahrfehlerdetektion

Die Methode zur Detektion von Einzelkorrekturen besteht aus drei Schritten: Zerlegung der stationären Kurvenfahrt in Handlungsprimitive, Merkmalsextraktion sowie anschließender Klassifikation bzw. Kennwertberechnung.

#### Zerlegung in Handlungsprimitive

Die Segmentierung der stationären Kurvenfahrt basiert auf der Rollbewegung des Fahrzeugs. Ein Handlungsprimitiv beginnt und endet mit aufeinanderfolgenden Nulldurchgängen des Signals der Rollrate<sup>145</sup>, da die Richtungsumkehr in der Regel<sup>146</sup> das Ergebnis einer durch den Fahrer eingeleiteten Lenkbewegung ist.

Zeitlich sehr kurze Handlungsprimitive, die einen Schwellwert  $t_{\min}$  unterschreiten, werden dem vorangegangenen oder nachfolgenden Handlungsprimitiv zugeordnet. Die Entscheidung darüber fällt anhand der Abfolge zweier Segmente. Ist nur eines zu kurz, wird es dem vorangegangenen zugeordnet. Sind beide zu kurz, wird das erste dem vorangegangenen und das zweite dem nachfolgenden Segment zugeordnet. Im zweiten Fall wird so die Abfolge von Handlungsprimitiven mit Rollbewegungen alternierenden Vorzeichens beibehalten. Aufeinanderfolgende Handlungsprimitive mit gleichem Vorzeichen werden zusammengefasst, da eine solche Abfolge nur infolge der vorangegangenen Aggregation entstehen kann und für die Auswertung alternierende Rollbewegungen per Definition ausgeschlossen werden.

#### Merkmalsextraktion

Für die Extraktion der Merkmale und die Klassifikation werden zwei aufeinanderfolgende Handlungsprimitive 1 und 2 betrachtet, siehe Abbildung 5-10. Aus dem Verbund werden die in Tabelle 5-3 aufgeführten Merkmale gewonnen.

Die Dauer ist in Kombination mit der Rollwinkeländerung und der Rollrate ein Indikator für die Kritikalität der Handlung. Lange Handlungen deuten darauf hin, dass die Handlung geplant ist oder notwendig, um dem Straßenverlauf zu folgen. Ist die Handlung dagegen kurz und besitzt eine hohe Rollrate und zudem signifikante Rollwinkeländerung, deutet dies auf eine notwendige Korrektur der Fahrtrajektorie hin.

---

<sup>145</sup> Vergleichbar mit Abbildung 4-6, Kapitel 4.4.3, S.39 für den Fall eines Schwellwerts von  $\dot{\varphi} = 0$ .

<sup>146</sup> In Sonderfällen kann die Lenkbewegung auch durch schlechte Straßenbedingungen, wie beispielsweise bei Schlaglöchern initiiert werden, die der Fahrer nicht vorhergesehen hat bzw. denen er nicht ausweichen konnte.

Tabelle 5-3: Merkmale zur Klassifikation eines Handlungsverbunds

Signal:	Beschreibung	Variable
Zeit	Dauer	$t_1, t_2$
	Relative Lage des Verbunds in der Sequenz	$t_{\text{rel}}$
Rollwinkel	Änderung im Handlungsprimitiv	$\Delta\varphi_1, \Delta\varphi_2$
Rollrate	Maximum (absolut) im Handlungsprimitiv	$\dot{\varphi}_{1,\text{max}}, \dot{\varphi}_{2,\text{max}}$
Bahnkrümmung <sup>147</sup>	Mittelwert von 1 s vor dem Verbund	$\kappa_0$
	Bei Beginn des Verbunds:	$\kappa_1$
	Bei Beginn des zweiten Handlungsprimitives	$\kappa_2$
	Bei Ende des Verbunds	$\kappa_3$
	Mittelwert der Sequenz von 1s nach dem Verbund	$\kappa_4$

Die relative Lage innerhalb der Sequenz der stationären Kurvenfahrt gibt Aufschluss darüber, wo die Handlung stattfindet, da Korrekturen des Einlenkvorgangs am Anfang der stationären Phase häufiger vorkommen als bspw. beim Verlassen.

Da die Straßenführung Einfluss auf den notwendigen Rollwinkel hat, wird die gefahrene Trajektorie in Form der Bahnkrümmung an fünf charakteristischen Punkten extrahiert. Dahinter steckt die Annahme, dass Handlungen, die auf eine Änderung der Kurvenkrümmung zurückzuführen sind und die außerhalb der sonst üblichen Schwankungen durch Regeleingriffe liegen, nicht fälschlicherweise als Korrekturen gewertet werden.




Abbildung 5-10: Subsegmentierung der stationären Kurvenfahrt und Merkmalsextraktion

<sup>147</sup> aus Rollwinkel & Geschwindigkeit berechnet.



## Klassifikationsmodell

Zur Bewertung und Klassifikation des Verbunds zweier Handlungsprimitive anhand des extrahierten Merkmalsvektors ist ein Modell notwendig, dass die Merkmale gewichtet und in Relation zueinander setzt, sodass fehlerfreie und fehlerbehaftete Handlungen maximal voneinander unterscheidbar sind.

Da die Dimensionalität des Merkmalsvektors und dessen Abhängigkeiten untereinander das Vorstellungsvermögen übersteigen, ist ein heuristisches Modell, wie bspw. bei der Bewertung der Regelgüte nicht praktikabel realisierbar. Die Modellbildung kann durch Verfahren des maschinellen Lernens gelöst werden. Gängige Verfahren sind beispielsweise: Entscheidungsbäume, Lineare Klassifikatoren Support Vektor Maschinen (SVM) oder Neuronale Netze.

Beim Training eines Klassifikators wird eine für die Kostenfunktion optimale Transformationsvorschrift  $\vec{x} \rightarrow T(\vec{x})$  gelernt, die dem Merkmalsvektor  $\vec{x}$  ein Klassifikationsergebnis  $T(\vec{x})$  zuordnet. Das Klassifikationsergebnis kann hierbei sowohl eine Kategorie als auch eine Wahrscheinlichkeit oder andere reell-wertige Größe für den Grad der Klassenzugehörigkeit sein.<sup>148</sup>

Verfahren, die ein Maß für die Klassenzugehörigkeit liefern, haben gegenüber Verfahren mit einem binären bzw. nicht skalierbaren Klassifikationsergebnis den Vorteil, dass die Klassenzugehörigkeit oder die Distanz zu einer Klassengrenze als Kennwert interpretiert werden kann. Entscheidungsbäume scheiden aus diesem Grund für die Auswertung der Kurvensegmente aus. Lineare Klassifikatoren haben gegenüber SVM und Neuronalen Netzen aufgrund der geringeren Flexibilität bei der Optimierung der Modellparameter während des Trainingsprozesses oftmals Nachteile bezüglich der Performance. Aus diesem Grund wird sich für ein einfaches Neuronales Netz entschieden.

Im Rahmen dieser Arbeit wurde sich zur Klassifikation des Merkmalsvektors für ein Multi-Layer-Perceptron (MLP) mit einer verdeckten Schicht eingesetzt, dass zur Kategorie der Neuronalen Netze gehört. Der Modellaufbau dieses MLP ist schematisch in Abbildung 5-11 dargestellt. Der Vorteil gegenüber einer SVM ist, dass die Anzahl der Modellparameter sowie die Struktur direkt vorgegeben werden kann und ein Neuronales Netzwerk ein universellerer Funktionsapproximator und –klassifikator ist.

---

<sup>148</sup> Vgl. Kroll, A.: Computational Intelligence (2016), S. 22.

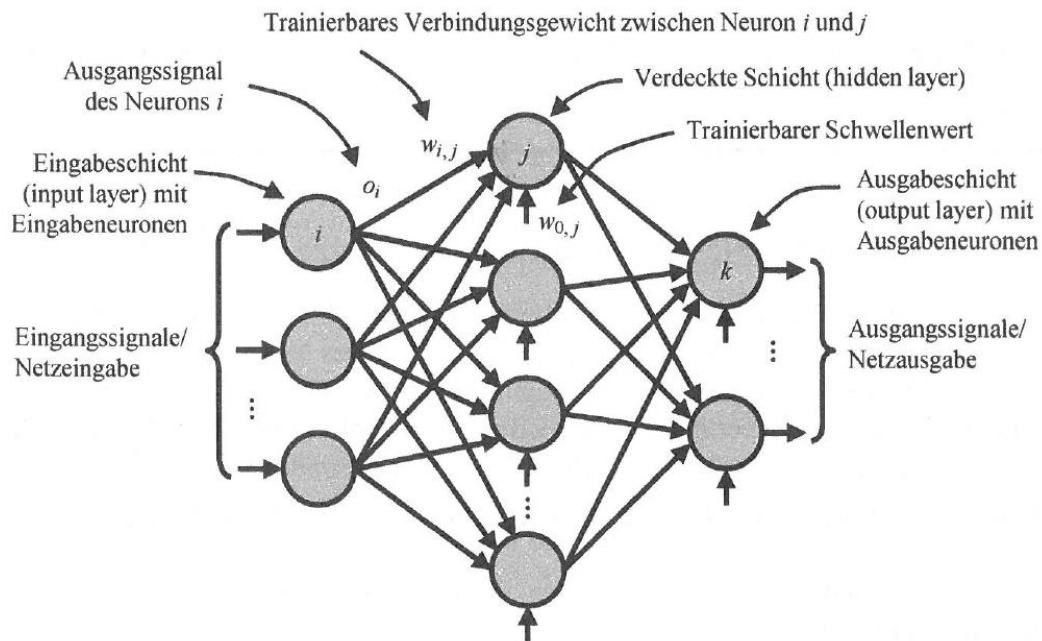


Abbildung 5-11: Aufbau eines Multi-Layer-Perceptrons mit zwei Ausgangssignalen zur binären Klassifikation<sup>149</sup>

Die Merkmale (Eingänge) werden der Eingabeschicht ohne Veränderung zugeführt. Diese erste Schicht von Neuronen dient anschließend dem Verteilen der Signale an die Neuronen der verdeckten Schicht. Während des Trainingsprozess werden die Gewichte, also die Verstärkung des Signals zwischen zwei Neuronen sowie der Offset angepasst. In der Ausgabeschicht werden die Signale der verdeckten Schichten anschließend zu Ausgangssignalen zusammengefasst und entsprechend des Betriebspunktes skaliert. Sowohl das dargestellte als auch das tatsächlich verwendete MLP, besitzen nur vorwärts gerichtete Verbindungen zwischen den einzelnen Schichten und sind damit rückkopplungsfrei bzw. besitzen kein Gedächtnis/Speicher. Das Training des Netzes, die Optimierung der Gewichte, erfolgt mittels Backpropagation-Algorithmus<sup>150</sup>, bei dem der Trainingsfehler, d.h. die Abweichung zwischen prädizierter und tatsächlicher Klasse, minimiert wird.<sup>151,152</sup>

<sup>149</sup> Kroll, A.: Computational Intelligence (2016), S. 225.

<sup>150</sup> Das Training des Modells in MATLAB erfolgt nach der Levenberg-Marquardt Optimierung die auch als Bayesian Regularization bekannt ist.

<sup>151</sup> Vgl. Kroll, A.: Computational Intelligence (2016), S. 225–250.

<sup>152</sup> Bishop, C. M.: Pattern recognition and machine learning (2009). Kapitel 5.1 - 5.3, S. 227-249

## Modelltraining und Auswahl

Für die beiden Muster Rollwinkel-Abbau und Rollwinkel-Aufbau wurden jeweils mehrere MLP-Klassifikatoren mit einer unterschiedlichen Anzahl an Neuronen in der verdeckten Schicht trainiert und evaluiert. Für das Training der Modelle werden die Sequenzen von Kurvenfahrten mit niedriger bzw. keiner vorhandenen Korrektur zur Repräsentation der positiven Klasse 0 und die Sequenzen mit sehr starken Korrekturen zur Repräsentation der negativen Klasse 1 ausgewählt. Der Fehler der Falschzuordnung einer Sequenz mit Korrektur wird höher gewichtet als die Falschklassifikation einer Sequenz ohne Korrektur. Dies ist darin begründet, dass eine Sequenz mit Korrektur in jedem Fall eine Information über die (mangelnde) Fahrertüchtigkeit enthält, während dies bei fehlerfreien Sequenzen nicht der Fall ist.

Theoretisch sollten die verbliebenen Datensätze von Sequenzen mit vorhandenen, aber weniger starken Korrekturen auf einer kontinuierlichen Skala für die Klassenzugehörigkeit von 0 bis 1 im mittleren Bereich zwischen den beiden Extremen liegen. Bei der Auswahl des Modells nach dem Training wird grundsätzlich ein Modell angestrebt, bei dem die Transformationsvorschrift  $\vec{x} \rightarrow T(\vec{x})$  dahingehend optimiert wurde, dass einzelne Klassifikationsergebnisse maximal voneinander unterscheidbar sind. Das bedeutet, dass die kumulierte Häufigkeitsverteilung des Grades der Klassenzugehörigkeit möglichst in keinem Bereich horizontal verläuft. In diesem Fall, so der Theorie nach, kann das zur binären Klassifikation trainierte Modell als kontinuierlicher Schätzer bzw. Regressor für die Kurvenfahrt Performance eingesetzt werden. Ein solches Modell ist beispielhaft in Abbildung 5-12: dargestellt.




Abbildung 5-12: Kumulierte Häufigkeitsverteilung des Grades der Klassenzugehörigkeit für die drei Klassen des Trainingsdatensatz zur Erkennung von fehlerhaften Einlenkvorläufen. Ebenfalls, in gestrichelter Linie, dargestellt sind die Häufigkeitsverteilungen einer vergleichbaren binären Klassifikation, wie sie jedoch nicht gewollt ist

## Kennwertbestimmung

Zur Bewertung der beiden Muster bzw. Fehler, die innerhalb einer Kurvenfahrt auftreten können werden zwei separate Modelle  $M_1$  und  $M_2$  trainiert.  $M_1$  repräsentiert dabei das Modell zur Erkennung des Fehlers vom Typ „Rollwinkel-Abbau“ während  $M_2$  zur Erkennung des Fehlers vom Typ „Rollwinkel-Aufbau“ trainiert wurde. Anschließend wird mit jedem der beiden Modelle jeder Merkmalsvektor  $\vec{x}_i$ , der ein einzelnes Handlungsprimitiv  $i$  innerhalb einer Kurvenfahrtsequenz repräsentiert, die Klassenzugehörigkeit  $P_1(\vec{x}_i)$  und  $P_2(\vec{x}_i)$  bestimmt. Als Kennwert für die gesamte Sequenz wird das Maximum der jeweiligen Kennwerte auf den Subsequenzen extrahiert.

$$K_{FK,RWab} = \max(P_1(\vec{x}_i)), P_1(\vec{x}_i) \in \mathbb{R} | 0 \leq f(x) \leq 1 \quad (5.16)$$

$$K_{FK,RWauf} = \max(P_2(\vec{x}_i)), P_2(\vec{x}_i) \in \mathbb{R} | 0 \leq f(x) \leq 1 \quad (5.17)$$

### 5.3.3 Zwischenfazit zur Arbeitshypothese

Zur Validierung der zuvor aufgestellten Arbeitshypothese:

*Es existieren Subsequenzen innerhalb der stationären Kurvenfahrt deren Rollwinkel- und Rollratenmuster auf Fahrfehler bzw. deren Korrekturen hinweisen. Die Auftretenshäufigkeit der Detektionen solcher Muster steht im Zusammenhang mit unterschiedlichen Fahrfertigkeitsniveaus.*

wird Abbildung 5-13 analysiert und diskutiert.




Abbildung 5-13: Kennwertverteilungen der Fahrfehlerdetektion gruppiert nach subjektiver Referenzeinteilung des Fahrfertigkeitsniveaus. Durchgezogen und fett dargestellt: Linkskurven. Gestrichelt und dünn dargestellt: Rechtskurven

Die Darstellung als kumulierte Häufigkeitsverteilung verdeutlicht bereits, dass die Kennwerte nicht normalverteilt sind und lässt vermuten, dass sie stattdessen einer Extremwertverteilung folgen. D.h. die Lage des Zentrums der Dichtefunktion ist zu einer Seite, in diesem Fall Richtung 0, ungleichmäßig verschoben und die Dichtefunktion ist nicht symmetrisch.

Die Kennwertverteilungen der unterschiedlichen Fahrergruppen lassen sich grundsätzlich gut visuell differenzieren. Zieht man beispielsweise gedanklich eine vertikale Linie bei einem Kennwert  $K_{\text{FK,Rollwinkelaufbau}}$ , ab dem eine Handlung als mindestens schwach ausgeprägter Fehler interpretiert werden kann, so lässt sich am Schnittpunkt mit der kumulierten Verteilung die „Fehlerhäufigkeit“ ablesen<sup>153</sup>. Beide Graphen zeigen, dass mit weniger Erfahrung die Wahrscheinlichkeit für einen Fehler in Linkskurven ansteigt. Auch hier können im ersten Schritt nur drei und nicht, wie eingeteilt, vier Gruppen identifiziert werden. Noch schwieriger ist es, die Gruppen anhand der Fehlerhäufigkeit in Rechtskurven zu identifizieren. Um diese am Fehlertyp „Rollwinkelaufbau“ erkennen zu können, wird eine große Menge an Daten benötigt, da die Fehlerhäufigkeiten sich nur im einstelligen Prozentbereich unterscheiden. Diese Annahme wird gestützt durch die Untersuchung der Verteilung mittels Zweistichproben Kolmogorov-Smirnov-Test. Dieser nicht-parametrische statistische Test überprüft, ob zwei Stichproben aus der gleichen kontinuierlichen Verteilung stammen oder alternativ aus zwei Verteilungen unterschiedlicher Parameter.

Zur Auswertung werden die Häufigkeitsverteilungen an  $N$  gleichmäßig über der  $y$ -Achse verteilten Punkten abgetastet, um Stichproben zu erzeugen, die bei geringerer Größe die gleichen statistischen Merkmale aufweisen. Anschließend werden zwei Stichproben paarweise gegeneinander getestet. Die Ergebnisse sind in Tabelle C-6 und Tabelle C- im Anhang zusammengefasst.

Die Arbeitshypothese kann aufgrund der festgestellten Unterschiede zwischen den Verteilungen auch aus statistischer Sicht nicht widerlegt werden. Insgesamt bewährt sich damit aus statistischer Perspektive die Annahme, dass die Auftretenswahrscheinlichkeit der Fahrfehlerkorrekturen ein Maß zur Differenzierung der Fahrfertigkeiten ist.

---

<sup>153</sup> Die Fehlerhäufigkeit ist dabei definiert als  $1 - H(K_{\text{FK,Rollwinkelaufbau}})$ , wobei  $H$  für die kumulierte Häufigkeit steht.

## 5.4 Linienwahl

Im Rahmen dieses Abschnitts wird die letzte der drei Arbeitshypothesen untersucht, welche besagt, dass auf Basis der Linienwahl innerhalb des zur Verfügung stehenden Freiraums, Bewertungsmetriken zur Beurteilung der Fahrfertigkeiten und Fahrerfahrung abgeleitet werden können. Ein Beispiel hierfür ist die von Crundall et al. im Fahrsimulator beobachtete lineare Verschiebung der Fahrzeugposition zur Kurvenmitte über dem Verlauf der Kurvenfahrt, die mit steigender Erfahrung zunimmt<sup>154</sup>.

Die Auswertung des zeitlichen Verlaufs der Querablage innerhalb der Fahrstreifenmarkierungen erfolgt vorrangig mit dem Ziel, zusätzliche, von der Regelgüte der Rollbewegung weitestgehend unabhängige Metadaten, Kennwerte und Metriken für die Fahrfertigkeitsklassifikation zu generieren. Dies wird in diesem Fall möglich, da die Fahrmanöver im Kontext des vorgegebenen Straßenverlaufs sowie des vorhandenen lateralen Freiraums ausgewertet werden.

### 5.4.1 Häufigkeitsverteilung Linienwahl

Neben der statistischen Verteilung von Kennwerten, die direkt aus der Zeitreihe der relativen Position extrahiert werden können, ist auch die Häufigkeitsverteilung bestimmter makroskopischer Trajektorien von Interesse. Die untersuchte Annahme lautet:

*Fahrertypen eines bestimmten Fahrfertigkeitsniveau lassen sich anhand der Auftretenshäufigkeit bestimmter Trajektorienmuster unterscheiden.*

Die zu klassifizierenden Muster sind dabei aufgrund der Randbedingung abgeleitet worden, dass sich das Vorzeichen der Rate der Querablage innerhalb des Verlaufs der stationären Kurvenfahrt nur ein Mal ändert.

Die gewählte Definition entstammt der Überlegung, dass eine Kurve mit konstanter Krümmung, mit einem konstanten Kurvenradius während stationärer Kurvenfahrt durchfahren werden kann, sofern die Bahnplanung korrekt war und der Einlenkpunkt entsprechend gewählt wurde. Die Definition lässt dabei genügend Freiheitsgrade zu, um sowohl die von Crundall et al. beobachtete lineare Veränderung über dem Kurvenverlauf abzubilden als auch die von Spiegel beschriebene „Sicherheits- und Rennlinie“<sup>155</sup> darzustellen.

---

<sup>154</sup> Crundall, E. et al.: Experiential differences across rider groups (2012).

<sup>155</sup> Vgl. Spiegel, B.: Die obere Hälfte des Motorrads (2009), S.82ff.

Die Sicherheitslinie ist dadurch gekennzeichnet, dass der geplante Kurvenscheitelpunkt in Richtung Kurvenausgang verschoben wird. Der Kurvenradius einer so gewählten Trajektorie wird dadurch am Anfang vergrößert, er ist im gefahrenen Scheitelpunkt dann jedoch kleiner als der vorgegebenen Kurvenradius. Bei einer so gefahrenen Kurve bleibt der Abstand zur inneren Fahrstreifenmarkierung im vorderen Bereich der Kurvenfahrt relativ konstant oder vergrößert sich. Trajektorien wie in Muster d) oder e) sind möglich.

Die Rennlinie oder auch zeitoptimierte Linie zielt darauf ab möglichst schnell, d.h. auf einem möglichst kurzen Weg bei gleichzeitig hoher Kraftschlussausnutzung und Geschwindigkeit, durch die Kurve zu fahren. Bei einer solchen gewählten Linie verkleinert sich der Abstand zur Kurveninnenseite typischerweise bis zum Kurvenscheitelpunkt und vergrößert sich während der Beschleunigungsphase wieder.

Insgesamt können mit obiger Definition neun unterschiedliche Muster für den Verlauf der Querablage abgebildet werden, exemplarisch in Abbildung 5-14 dargestellt.




Abbildung 5-14: Exemplarische Verläufe der Querablage für fehlerfreie Kurvenfahrten. a) Folgen des Fahrbahnverlaufs ohne relative Verschiebung. b/c) konstante Verschiebung nach kurvenaußen/kurveninnen. d) Sicherheitslinie, spitzenfahren der Kurven mit möglichst kleinem Kurvenradius am Scheitelpunkt. e/f) nichtlineare Verschiebung nach kurvenaußen. g) Rennlinie, starkes schneiden der Kurve. h,i) nichtlineare Verschiebung nach kurveninnen

### Modell zur Klassifikation der Linienwahl

Die unterschiedlichen Trajektorien können gemäß ihrer Definition anhand der Gradienten über der Zeit klassifiziert werden. Um der Variation auftretender Kurven im Realverkehr gerecht zu werden, werden mehrere Regressionsmodelle mit unterschiedlichen Parametern und Randbedingungen angewendet, um Merkmale zur Klassifikation zu extrahieren. Für die Regression eignen sich im hier vorliegenden Fall besonders Splines mit linearen Abschnitten zwischen den Knotenpunkten. Bei dieser Wahl kann für jedes Segment zwischen zwei Knotenpunkten die Randbedingung der Steigung der Geraden für die numerische Optimierung formuliert werden. Im Optimierungsschritt werden anschließend die zu den vorliegenden Daten optimalen Knotenpunkte bestimmt.

Zur Unterscheidung der neun Trajektorienverläufe werden drei Modelle verwendet, zusammenfassend beschrieben in Tabelle 5-4. Das erste und einfachste Modell besteht aus zwei Knotenpunkten und keiner Randbedingung für die Steigung auf diesem einen Segment. Damit lassen sich bereits zwei charakteristische Merkmale zur Klassifikation der Muster a), b) und c) bestimmen. Diese sind das Bestimmtheitsmaß  $R_{TM_1}^2$  des linearen Regressionsmodells  $TM_1$  sowie die Veränderung der Position im Fahrstreifen  $\Delta d_{FM}$ .

Das zweite und dritte Modell besitzen jeweils fünf Knotenpunkte. Für Modell zwei gelten dabei die Randbedingungen das Segment 1 und 2 eine Steigung  $m_{1/2} \geq 0$  aufweisen und Segment 3 bzw. 4 entsprechend  $m_{1/2} \leq 0$ .

Tabelle 5-4: Übersicht der Regressionsmodelle zur Trajektorien Approximation

Modell	Knoten / (Segmente)	Randbedingung	Extrahierte Merkmale
$TM_1$	2 (1)	Keine	$R_{TM_1}^2$ : Bestimmtheitsmaß $TM_1$ $\Delta d_{FM} = d_{FM,end} - d_{FM,1}$ : Veränderung der Querablage innerhalb Kurve
$TM_2$	5 (4)	$m_1 \geq 0, m_2 \geq 0,$ $m_3 \leq 0, m_4 \leq 0$	$R_{TM_2}^2$ : Bestimmtheitsmaß $TM_2$ $\Delta d_{FM, TM_2, 1} = m_1 \cdot t_1 + m_2 \cdot t_2$ : Veränderung der Querablage des 1. und 2. Abschnitts des Modells $TM_2$ $\Delta d_{FM, TM_2, 2} = m_3 \cdot t_3 + m_4 \cdot t_4$ : Veränderung der Querablage des 3. und 4. Abschnitts des Modells $TM_2$
$TM_3$	5 (4)	$m_1 \leq 0, m_2 \leq 0,$ $m_3 \geq 0, m_4 \geq 0$	$R_{TM_3}^2$ : Bestimmtheitsmaß $TM_3$ $\Delta d_{FM, TM_3, 1} = m_1 \cdot t_1 + m_2 \cdot t_2$ : Veränderung der Querablage des 1. und 2. Abschnitts des Modells $TM_3$ $\Delta d_{FM, TM_3, 2} = m_3 \cdot t_3 + m_4 \cdot t_4$ : Veränderung der Querablage des 3. und 4. Abschnitts des Modells $TM_3$



Aufgrund der fünf zu bestimmenden Knotenpunkte lassen sich theoretisch bereits die verbliebenen sechs Muster approximieren und klassifizieren, da bei der Optimierung zwei oder mehr Knotenpunkte theoretisch auf denselben Punkt fallen können. Zur Verbesserung und Vereinfachung der nachfolgenden Erkennungslogik wird das dritte Modell verwendet, welches inverse Randbedingungen zu Modell zwei aufweist. Die zu den Modellen zugehörigen Modellparameter, Randbedingungen und extrahierten Merkmale sind in Tabelle 5-4 zusammengefasst. Anhand der extrahierten Merkmale erfolgt die Klassifikation der Kurvensegmente entsprechend der Logik des in Abbildung 5-15 abgebildeten Entscheidungsbaums.

Die Logik beruht dabei auf dem Vergleich der Merkmale untereinander sowie mit den drei Parametern, die im Folgenden begründet werden:

- $\alpha = 0,9$ : Ein minimaler Schwellwert für das Bestimmtheitsmaßes ist notwendig, da die modellbasierte Klassifikation nur Sinn ergibt, wenn das Modell auch in der Lage ist, die Daten entsprechend zu erklären.
- $\beta = 0,2$  m: Veränderungen von bis zu 0,2 m werden nicht als beabsichtigte Positionsveränderung erachtet. Dies erscheint ebenfalls aus Sicht der Messunsicherheit der Fahrstreifenpositionierung, bei 0,1 m liegt, sinnvoll.
- $t_{\min} = 1$  s: Spline Segmente mit einer Dauer von weniger als einer Sekunde werden als vernachlässigbar für die Approximation erachtet.

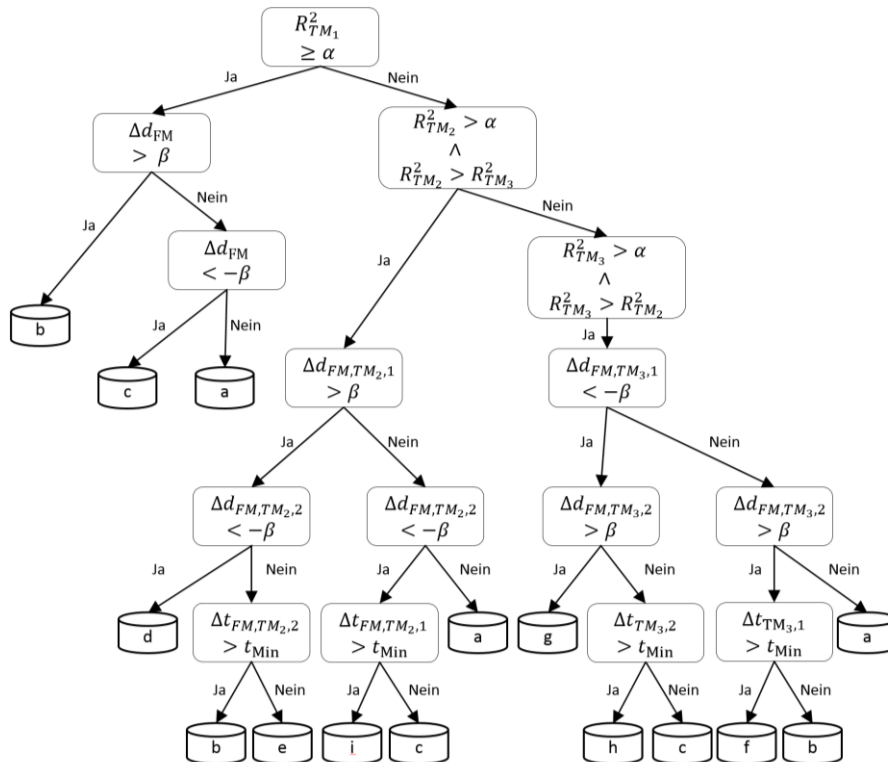


Abbildung 5-15: Logik zur Klassifikation der gefahrenen Trajektorie, dargestellt als Entscheidungsbaum

## Zwischenfazit

Das Ergebnis des aufgezeigten Klassifikationsverfahrens für die vom Fahrer gewählte Linie zeigt Abbildung 5-16. Wie bereits an der großen Schwankung zu erkennen, gibt es deutliche Unterschiede zwischen den Fahrern. Dabei sind die Differenzen zwischen den Fahrern der gleichen Gruppen ähnlich hoch, wenn nicht sogar größer, wie die Unterschiede zwischen den Mittelwerten der Gruppen. Auffällig ist dabei, dass sich Fahranfänger vom Rest der Gruppen dahingehend unterscheiden, dass Sie ca. 10 bis 15 % seltener Kurvenfahrten nach dem Muster c) durchgeführt haben. Kombiniert man die Muster c) und h), beides Trajektorien, bei denen ab dem Einlenkvorgang bis zum Aufrichten des Fahrzeugs ausschließlich eine Verschiebung zur Kurveninnenseite stattfindet, liegt der Unterschied sogar bei 16 bis 21%. Die Beobachtungen von Crundall et. al, dass mit steigender Erfahrung eine größere Verschiebung der Fahrzeugposition nach Kurveninnen zu beobachten ist<sup>156</sup>, kann somit auch mit Realfahrdaten von unterschiedlichen Kurvenfahrten anhand der Auftretenswahrscheinlichkeit unterschiedlicher Linienwahl gestützt werden.




Abbildung 5-16: Verteilung der Linienwahl nach Klassifikation des Verlaufs der Querablage gruppiert nach Fahrerfahrung. Die Fehlerbalken geben die obere und untere Grenze der Gruppen-internen Schwankungen bei Fahrerindividuellen Auswertung an

Weiter ist auffällig, dass die Trajektorien der Fahranfänger häufiger als Unbekannt klassifiziert werden. Dies ist aufgrund der Klassifikation anhand des Bestimmtheitsmaße mit

<sup>156</sup> Vgl. Crundall, D. et al.: Study on motorcycle experience and training (2014).

den Regressionsmodellen zu erklären. Fahranfänger neigen wie erwartet<sup>157</sup> häufiger dazu, ihre Linie innerhalb einer länger andauernden stationären Kurvenfahrt zu korrigieren. Dementsprechend sinkt die Korrelation zu einem Modell, dass nur einen Vorzeichenwechsel des Querablage-Gradienten zulässt.

Ein dritter Diskussionspunkt ist die Auftretenswahrscheinlichkeit von Muster d), bei dem sich das Fahrzeug von der Kurveninnenseite zuerst entfernt und anschließend wieder nähert. Die Auftretenswahrscheinlichkeit einer solchen Linienwahl ist für Vielfahrer augenscheinlich deutlich geringer als für den Rest der Fahrer. Das wirft die Frage auf, ob ein solcher Verlauf vielleicht eher in die Kategorie „fehlerbehaftet“ fällt?

Insgesamt lässt sich feststellen, dass durch die diskrete Klassifikation der Linienwahl Vielfahrer von Fahranfängern unterschieden werden können und die Unterschiede logisch nachvollziehbar sind und mit Studienergebnissen anderer Untersuchungen übereinstimmen. Die Unterschiede können jedoch mit den Modellen und daraus abgeleiteten Metriken für die Klassifikation ebenfalls „metrisch“ quantifiziert werden, wie im nachfolgenden Abschnitt gezeigt wird.

## 5.4.2 Positionsvariation und Positionsverschiebung

Die Regression mit den zuvor eingeführten Modellen ist aus signaltechnischer Sicht eine modellbasierte Glättung des Signalverlaufs der Querablage im Fahrstreifen. Die nicht durch das Modell erklärbare Varianz der Positionsdaten, trotz der oben beschriebenen Freiheitsgrade bei der Regression, wird hypothetisch auf die Fertigkeiten des Fahrers zurückgeführt. Analog zu Unterkapitel 5.2 wird daher die Positionsvariation während der Kurvenfahrt aus der Abweichung zu einem idealisierten Modell bestimmt. Als Kennwert wird das Minimum der mittleren Abweichung der Fehlerquadrate zwischen Regressionsmodell und den Originaldaten der beide Modelle  $TM_2$  und  $TM_3$  gewählt, siehe Formel (5.18). Als alternative Kenngröße kann das Maximum der beiden Bestimmtheitsmaße  $R_{TM_2}^2$  und  $R_{TM_3}^2$  verwendet werden. Im Unterschied zu  $K_{LW,Well}$  beschreibt dieser Kennwert den Erklärungsgrad der Daten mittels der Regressionsmodelle und verfolgt aus statistischer Perspektive eine inverse Philosophie<sup>158</sup>. Beide Kennwerte weisen quasi identische Merkmale zur Klassifikation der Trajektorie auf, sodass für die weiteren Untersuchungen ausschließlich  $K_{LW,Well}$  betrachtet wird.

$$K_{LW,Well} = \min(\text{RMSE}(TM_2), \text{RMSE}(TM_3)) \quad (5.18)$$

---

<sup>157</sup> Stärker ausgeprägte Rollwinkeländerung wie im vorangegangenen Kapitel festgestellt, führen zwangsweise auch zu „mehr“ schwankender bzw. oszillierender Positionsänderung im Fahrstreifen.

<sup>158</sup> Quantifizierung des Erklärbaren vs. Quantifizierung des Fehlers, d.h. der unbeobachteten Effekte.

$$K_{LW,Well,R^2} = \max(R_{TM_2}^2, R_{TM_3}^2) \quad (5.19)$$

Aus den Regressionsmodellen ist weiterhin die geglättete Verschiebung der Position (Index „ΔPos“) zur Kurveninnenseite (Index „in“) wie Kurvenaußenseite (Index „au“) bekannt, siehe Tabelle 15. Somit ist ein Maß für die Ausnutzung des zur Verfügung stehenden Freiraums innerhalb der Fahrbahnmarkierungen in beide Richtungen verfügbar.

$$K_{LW,\Delta Pos,in} = \begin{cases} \Delta d_{FM, TM_2, 1} & \text{wenn } R_{TM_2}^2 > R_{TM_3}^2 \\ \Delta d_{FM, TM_3, 2} & \text{wenn } R_{TM_2}^2 \leq R_{TM_3}^2 \end{cases} \quad (5.20)$$

$$K_{LW,\Delta Pos,au} = \begin{cases} \Delta d_{FM, TM_2, 2} & \text{wenn } R_{TM_2}^2 > R_{TM_3}^2 \\ \Delta d_{FM, TM_3, 1} & \text{wenn } R_{TM_2}^2 \leq R_{TM_3}^2 \end{cases} \quad (5.21)$$

### Zwischenfazit

Die Verteilung der eingeführten Kennwerte und Merkmale sind in Abbildung 5-17 und Abbildung 5-18 dargestellt. Die nicht mit den Modellen zur Trajektorien-Approximation erklärbare Positionsvariation ist für Fahrer mit weniger Fahrerfahrung, wie in der Arbeitshypothese formuliert, stärker ausgeprägt. Visuell können sowohl in Rechtskurven wie in Linkskurven drei Gruppen identifiziert werden. Die Gruppenzusammensetzung sind jedoch unterschiedlich, in Rechtskurven liegen die statistischen Verteilungen von Vielfahrern eng bei denen von Normalfahrern. In Linkskurven sind dagegen Normalfahrer weniger gut von ungeübten Fahrern zu unterscheiden. Die Gruppe von Fahranfängern sind in beiden Fällen gut vom Rest der Probandengruppen abgrenzbar, da die Verteilung zu höheren Kennwerten verschoben ist. Fahranfänger tendieren also stärker dazu, die Linie anzupassen bzw. zu korrigieren und sind unsicherer in ihrer Linienwahl.




Abbildung 5-17: Verteilung der Kennwerte zur Auswertung der nicht modellhaft erklärbaren Positionsvariation während stationärer Kurvenfahrt

Es konnte ebenfalls festgestellt werden, dass sich die Differenzierbarkeit von ungeübten Fahrern und Fahranfängern gegenüber Fahrern mit mehr Fahrerfahrung mit zunehmender Kurvenlänge verstärkt. Auffällig ist dabei, dass sich die Gruppe der Normalfahrer sowohl für Links- als auch für Rechtskurven der Verteilung der Vielfahrer annähert.

Diese Beobachtung ist besonders vor dem Hintergrund interessant, dass bei der Bewertung der Rollbewegung Vielfahrer gut von den Normalfahrern abgrenzbar waren, nicht so gut jedoch von ungeübteren Fahrern. Erwartet wurde, dass die Kennwertverteilungen sich aufgrund der Kopplung von Rollbewegung und Positionsverschiebung stärker ähnlich sind. Bei der finalen Klassifikation der individuellen Fahrfertheitsniveaus kann diese Beobachtung von Vorteil sein, da die Differenzierbarkeit mit steigender Anzahl unabhängiger Unterscheidungsmerkmale steigt.

Neben den Ergebnissen der Positionsvariation zeigt auch die Auswertung der kontinuierlichen Positionsverschiebung (Abbildung 5-18), dass zwischen Fahranfängern und dem restlichen Fahrerkollektiv unterschieden werden kann, wertet man die Verschiebung zur Kurveninnenseite aus. Fahranfänger verschieben ihre Position so beispielsweise nur in 20 % der Kurvenfahrten um mehr als einen halben Meter, während die restlichen Fahrergruppierungen dies im Mittel in ca. 40 % der Fälle tun. Weitere Unterschiede zwischen den Fahrergruppierungen können nicht identifiziert werden.




Abbildung 5-18: Verteilung der geglätteten kontinuierlichen Positionsverschiebung in Richtung Kurvenmitte ( $K_{LW,\Delta Pos,in}$ ) oder Kurvenaußenseite ( $K_{LW,\Delta Pos,au}$ ) während stationärer Kurvenfahrt

Die Auswertung der Fahrerindividuellen Verschiebung in Unterkapitel 7.2 zeigt, dass durchaus mehr Unterschiede zwischen den einzelnen Fahrern identifiziert werden können, als dies anhand dieser gruppierten Darstellung möglich ist.

Im Gegensatz zur Positionsverschiebung zur Kurveninnenseite sind bei der Auswertung der Verschiebung zur Kurvenaußenseite keine signifikanten Unterschiede oder Auffälligkeiten zu beobachten, die sich auf die Fahrerfertigkeiten zurückschließen lassen. Die

Spannweite der Verteilung ist dabei mit ca. 0,7 m nur etwa halb so groß wie die der negativen Positionsverschiebung von  $> 1.5$  m.

Insgesamt lässt sich zusammenfassen, dass durch die Auswertung der Fahrstreifenposition innerhalb der Fahrstreifenmarkierung weitere diskriminative Merkmale zur Beurteilung der Fahrerfertigkeiten gewonnen werden können, die in weiten Teilen unabhängig von den Kennwerten und Merkmalen der Rolldynamik sind.

---

## 6 Methoden zur Bewertung nicht-stationärer Kurvenfahrt

In Kapitel 6 werden die Phasen der dynamischen Kurvenfahrt näher analysiert. Dies umfasst sowohl das Einlenken in eine Rechts- oder Linkskurve als auch das Abschließen der Kurvenfahrt und dem damit verbundenen Aufrichten des Motorrads. Basierend auf den im Realverkehr vorgefundenen zeitlichen Verläufen von Rollrate, Rollwinkel sowie der Querablage im Fahrstreifen werden heuristische Modelle zur Bewertung der Sequenzen abgeleitet. Aus deren Häufigkeitsverteilung ist es möglich, Indikatoren für die Fahrfertigkeiten von Motorradfahrern abzuleiten.

Der Einlenk- sowie Auslenkvorgang, also die Rollbewegung auf den notwendigen Schräglagenwinkel oder das Verlassen der Kurvenfahrt in die aufrechte Position, kann im Idealfall als eine ballistische Bewegung interpretiert werden. Das Profil der Rollrate folgt dabei dem Verlauf einer Glockenkurve, kann bei sehr kurzen Einlenkvorgängen mit großen Zielrollwinkeln aber auch in ein abgerundetes Dreieckprofil<sup>159</sup> übergehen. Zurückzuführen ist dieses zeitliche Profil auf die menschliche Bewegungssteuerung, in diesem Fall der Steuerung der Hand- und Armbewegung für den initialen Lenkimpuls, deren Geschwindigkeitsprofil ebenfalls einer Glockenkurve folgt. Durch die Kopplung von Lenkimpuls und Rollbewegung überträgt sich dieser Verlauf auf das Fahrzeug.<sup>160,161,162</sup> Gestützt wird diese These durch die Studie von Benderius und Markkula zum Lenkverhalten von Fahrzeugführern. Sie konnten zeigen, dass das Lenkradwinkel-Geschwindigkeitsprofil durch eine einfache Glockenfunktion in 60-72 % der untersuchten Fälle mit einem Bestimmtheitsmaß von  $R^2 > 0,8$  angenähert werden kann. Der verbleibende Anteil kann zudem durch zwei oder mehr Glockenkurven besser approximiert werden.<sup>163 164</sup>

---

<sup>159</sup> Mit zunehmender Rollratenamplitude aber gleichbleibender Dauer des Einlenkvorgangs wird das Rollratenprofil zunehmend spitzer, siehe hierzu auch Abbildung 6-1 links, blaue vs. rote Kurve.

<sup>160</sup> Morasso, P.: Spatial control of arm movements (1981).

<sup>161</sup> Atkeson, C. G.; Hollerbach, J. M.: Kinematic features of unrestrained vertical arm movements (1985).

<sup>162</sup> Grimme, B. et al.: Naturalistic arm movements during obstacle avoidance in 3D and the identification of movement primitives (2012).

<sup>163</sup> Vgl. Benderius, O.; Markkula, G.: Bell-Shaped Steering Corrections (2014), S. 886.

<sup>164</sup> Vgl. Markkula, G.: Driver behavior models for evaluating automotive active safety (2015), S. 22–23.

Ein fehlerhaftes Einlenken, z.B. Einlenken an einer falschen Position oder mit zu starkem bzw. zu schwachem initialen Lenkimpuls führt dazu, dass das Rollratenprofil von der beschriebenen ballistischen Kurve abweicht und folgende zwei Phänomene zu beobachten sind:

- Es kommt zu deutlich ausgeprägten, der Glockenkurve überlagerten, Rollratenvariationen in Form von hochfrequenten Schwingungen.
- Es kommt zu zwei oder mehr ausgeprägten Maxima innerhalb des Einlenkvorgangs, die durch die dazwischenliegenden Minima deutlich voneinander abgegrenzt werden können.

Die Rollraten Verläufe für drei fehlerfreien ballistischen Einlenkvorgänge sowie für zwei Einlenkvorgänge mit Korrektur, in Form eines zweiten Maxima, sind in Abbildung 6-1 nebeneinander dargestellt.




Abbildung 6-1: Fehlerfreie (links) und fehlerbehaftete (rechts) Einlenkvorgänge unterschiedlicher Kurvenfahrten (farbig kodiert)

Aus den Erkenntnissen und Beobachtungen sind folgende zwei Arbeitshypothesen abgeleitet:

H4.1:

*Fehlerfreie Rollwinkeländerung zu Beginn oder beim Verlassen einer Kurvenfahrt können mittels Regressionsmodellen, die einem Glockenkurven-Verlauf ähnlich sind mit geringem Fehler approximiert werden. Die Häufigkeitsverteilung eines Approximationsgütemaßes ermöglicht daher unterschiedliche Fahrfertigkeitsniveaus zu identifizieren.*



H4.2:

*Bestimmte Frequenzanteile im Rollratensignals während der dynamischen Rollwinkeländerung sind charakteristisch für fehlerbehaftete Einlenkvorgänge. Die Häufigkeitsverteilung dieser Frequenzanteile im Rollratensignal ermöglicht auf das Fahrfertigkeitsniveau zu schließen.*

### **Testdatensatz**

Zur Untersuchung und Validierung der nachfolgenden Kennwerte zur Bewertung der nicht-stationären Kurvenfahrt wurde ein Datensatz von 500 Einlenkvorgängen annotiert. Hierfür wurde die selbe dreistufige Ordinalskala genutzt, wie für die subjektive Bewertung der stationären Kurvenfahrt.<sup>165</sup> Rollratenverläufe, die sich durch eine Glockenkurve, wie in Abbildung 6-1 links, approximieren lassen und auf ein fehlerfreies Einlenken hindeuten, wurden mit der Bewertung „kein/wenig“-Korrektur gekennzeichnet. Rollratenverläufe, die zwei oder mehr deutliche Maxima innerhalb der Sequenz des Einlenkvorgangs aufweisen, siehe Abbildung 6-1 rechts, erhalten die Bewertung „hohe/starke“-Korrektur. Sequenzen mit leichten Schwankungen und Korrekturen, die nicht eindeutig einer der beiden Extreme zuzuordnen sind, werden der Klasse mit „mittleren“-Korrekturen zugewiesen.

Basierend auf diesen subjektiven Bewertungen werden die einzelnen Kennwerte untersucht und bezüglich der Differenzierbarkeit zwischen den drei Klassen validiert und optimiert.

---

<sup>165</sup> Siehe Tabelle 5-1

## 6.1 Frequenzselektierendes Filterverfahren

Abschnitt 1. befasst sich mit der Untersuchung der Arbeitshypothese H4.2., dass bestimmte im Rollratensignal enthaltene Frequenzen, während des Einlenkvorgangs, charakteristisch für fehlerfreie oder fehlerbehaftete Handlungen sind. Die Hypothese besagt weiter, dass anhand der statistischen Verteilung Fahrer mit unterschiedlicher Fahrerfahrung voneinander trennbar sind.

### 6.1.1 Filterverfahren

Das Filterverfahren entspricht dem bereits zur Bewertung der stationären Kurvenfahrt eingesetzten Vorgehen<sup>166</sup>. Das Signal der Rollrate wird phasenverzugsfrei durch vorwärts- und rückwärts filtern und mit Einbezug vorangegangener und nachfolgender Samples gefiltert, um Artefakte zu vermeiden. Als Filter wird abermals je ein Butterworth-Hoch- und Tiefpassfilter 2. Ordnung verwendet, um einen Bandpassfilter zu realisieren, dessen Einschwingdauer eine halbe Sekunde beträgt und damit 25 % der Dauer typischer Einlenksequenzen.

Vor dem Filterschritt (6.2) wird das Signal der Rollrate  $\dot{\phi}(t)$  normiert, sodass die Maximalamplitude jeder normierten Sequenz eins beträgt. Die Notwendigkeit der Normierung ergibt sich aus dem Sachverhalt, dass zwei Sequenzen identischen Verlaufs mit unterschiedlich hohen Amplituden ein entsprechend dem Amplitudenverhältnis verschobenes Frequenzspektrum aufweisen. Ohne Normierung wären dementsprechend auch die gefilterten Signalverläufe um diesen Faktor verschoben, was zu wenig vergleichbaren Kennwerten führen würde.

$$\dot{\phi}_{\text{Seq,norm}}(t) = \frac{\dot{\phi}_{\text{Seq}}(t)}{\max(|\dot{\phi}_{\text{Seq}}(t)|)} \quad (6.1)$$

$$\check{\phi}_{BP}(t) = BP(\dot{\phi}_{\text{Seq,norm}}(t), f_{G,HP}, f_{G,TP}) \text{ mit } f_{G,TP} > f_{G,HP} \quad (6.2)$$

Der Kennwert zur Bewertung des Einlenkvorgangs wird aus der Wurzel des Integrals des quadrierten bandpassgefilterten Signals gebildet.

$$K_{E,\text{Freq}} = \sqrt{\int_0^{t_{\text{seq}}} \check{\phi}_{BP}(t)^2 dt} = \frac{1}{10 \text{ Hz}} \cdot \sqrt{\sum_{i=1}^N \check{\phi}_{BPi}^2} \quad (6.3)$$

<sup>166</sup> Vergleich Kapitel 5.2.1

### 6.1.2 Optimierung der Grenzfrequenzen

Für die Erkennung von fehlerhaften Einlenkvorgängen sowie der Fahrfertigkeiten sind als freie Parameter die obere und untere Eckfrequenz des Bandpassfilters zu wählen. Die Optimierung erfolgt zum einen hinsichtlich der Trennung von fehlerfreien und fehlerbehafteten Sequenzen, zum anderen zur Trennung von Fahrern mit hohen und niedrigen angenommenen Fahrfertigkeiten. Im ersten Fall wird der annotierte Datensatz genutzt, im zweiten Fall werden die Ergebnisse der Kennwertberechnung für eine Auswahl an Kurvenfahrten von einem Fahrer mit hoher angenommener Fahrfertigkeit mit denen eines Fahrers mit vermeintlich niedriger Fahrfertigkeit verglichen. In beiden Fällen wird die  $t$ -Statistik als Kostenfunktion zur Optimierung herangezogen. Die Ergebnisse sind in Abbildung 6-2 visualisiert.

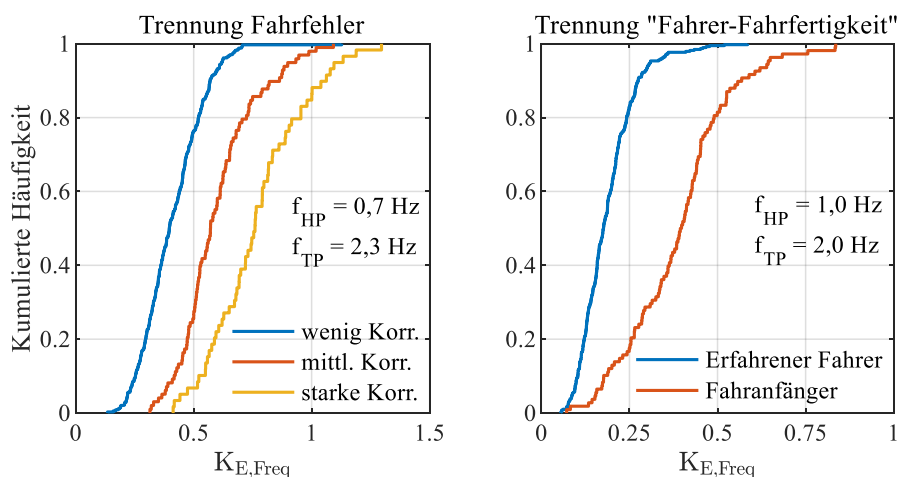


Abbildung 6-2: Kumulierte Häufigkeit der Bewertung von Einlenkvorgängen mit Frequenzkennwert

Zur Trennung von fehlerfreien und fehlerbehafteten Einlenkvorgängen liegt die optimale untere Grenzfrequenz des Bandpassfilters bei 0,7 Hz, während die obere Grenzfrequenz bei 2,3 Hz liegt. An der Häufigkeitsverteilung ist darüber hinaus zu erkennen, dass 70 % der Einlenkvorgänge mit starker Korrektur einen größeren Kennwert haben als das 99. Perzentil der fehlerfreien Sequenzen. Die subjektiv als mittlere Korrektur klassifizierten Sequenzen liegen erwartungsgemäß zwischen den beiden Verteilungen.

Für die optimale Trennung von Fahrern mit unterschiedlichen Fahrfertigkeiten, gemäß der Optimierung auf die  $t$ -Statistik, ist das Signal des Rollratenverlaufs mit einem Bandpass mit unterer Grenzfrequenz von 1 Hz und obere Grenzfrequenz von 2 Hz zu filtern. Im Unterschied zur Trennung der Fahrfehler liegen die Häufigkeitsverteilungen im unteren Bereich des Kennwerts dichter beieinander. Der flache Anstieg der kumulierten Häufigkeit über dem Kennwert  $K_{E,Freq}$  führt jedoch dazu, dass bereits das 20. Perzentil des Fahranfängers mit dem 80. Perzentil des professionellen Testfahrers zusammenfällt.

Anschaulich bedeutet das, dass bei zufälliger Auswahl einer Stichprobe von 20 Bewertungen des Einlenkvorgangs in eine Kurvenfahrt, in über 99 % der Fälle ein Unterschied in den Mittelwerten der Verteilungen mit einer Irrtumswahrscheinlichkeit von kleiner als 5 % statistisch nachgewiesen werden kann.

Problematisch am realisierten Filter mit Durchlassbereich von 1 bis 2 Hz ist, dass die Einschwingdauer gegenüber einem Bandpass mit Grenzfrequenzen von 0,7 und 2,3 Hz um eine halbe Sekunde auf insgesamt eine Sekunde ansteigt. Dies kann bei den zeitlich kurzen Einlenkvorgängen zum Auftreten von Filterartefakten führen. Da die Verbesserung der Trennschärfe der Fahrer durch den kleineren Durchlassbereich nur marginal ist, wird für alle weiteren Untersuchung im Rahmen dieser Arbeit der Bandpassfilter mit dem Durchlassbereich von 0,7 bis 2,3 Hz verwendet.

## 6.2 Regressionsbasiertes Verfahren

Der zweite verfolgte Ansatz basiert auf den Erkenntnissen von Benderius und Markkula, dass sich das Lenkradwinkel-Geschwindigkeitsprofil und damit dessen Äquivalent beim Motorradfahren, das Rollratenprofil, durch eine Glockenkurve approximieren lässt<sup>167</sup>. Die Arbeitshypothese lautet, dass das Rollratenprofil umso besser approximiert werden kann, desto besser die Ausführung des Einlenkvorgangs war, d.h. umso mehr sie einer ballistischen Bewegung ähnlich ist.

Die Analyse der aufgenommenen Sequenzen zeigt auch, dass bei sehr schnellen Rollbewegungen das Rollratenprofil spitz zuläuft und von einer Glockenkurve in einen Dreiecksverlauf übergehen kann. Zur Detektion von Einlenkfehlern und der Hypothese das sich anhand deren Häufigkeit die Fahrer unterschiedlicher Fahrfertigkeitsniveaus unterscheiden lassen, werden daher diese zwei Regressionsmodelle parallel untersucht.

### 6.2.1 Regressionsmodelle

Das mathematische Modell der gaußschen Glockenkurve zur Approximation des normierten Rollratenprofils ist definiert durch Formel (6.4). Dabei bestimmen die Koeffizienten  $c_i$  folgende Größen:  $c_1$ : Maximale Höhe,  $c_2$ : Zentrum der Glocke und  $c_3$ : Breite der Glockenkurve.

$$G_{\text{Gauss1}}(t) = c_1 \cdot \exp \frac{-(c_2 - t)^2}{c_3} \quad (6.4)$$

---

<sup>167</sup> Vgl. Benderius, O.; Markkula, G.: Bell-Shaped Steering Corrections (2014), 886f.

Benderius und Markkula haben gezeigt, dass nicht alle Lenkbewegungen mit einer einfachen Glockenkurve angenähert werden können, sondern zwei oder gar drei Glockenkurven notwendig sind<sup>168</sup>. Deshalb wird für die Definition eines zweiten Kennwerts, der normierte Rollratenverlauf während des Einlenkvorgangs mit einem Regressionsmodell bestehend aus zwei Glockenkurven approximiert. Das Regressionsmodell lautet dann wie folgt:

$$G_{\text{Gauss2}}(t) = c_{1,1} \cdot \exp \frac{(c_{2,1}-t)^2}{c_{3,1}} + c_{1,2} \cdot \exp \frac{(c_{2,2}-t)^2}{c_{3,2}} \quad (6.5)$$

Die beiden Kennwerte  $K_{\text{E,Gauss1}}$  und  $K_{\text{E,Gauss2}}$  zur Bewertung des Einlenkvorgangs werden aus der Differenz des Regressionsmodells und dem gemessenen und gemäß Formel (6.1) normierten Rollratensignal  $\dot{\phi}(t)$  definiert.

$$K_{\text{E,Gauss1}} = \frac{1}{f_{\text{Abtast}}} \cdot \sqrt{\sum (\dot{\phi}_{\text{norm}}(t) - G_{\text{Gauss1}}(t))^2} \quad (6.6)$$

$$K_{\text{E,Gauss2}} = \frac{1}{f_{\text{Abtast}}} \cdot \sqrt{\sum (\dot{\phi}_{\text{norm}}(t) - G_{\text{Gauss2}}(t))^2} \quad (6.7)$$

### Spline Regressionsmodell

Das alternative Spline-Modell  $S_{\text{E}}(t)$  zur Approximation von spitz zulaufenden Rollratensignalen und anderen glatten, aber nicht glockenförmigen Rollratenverläufen, besitzt drei Knotenpunkten  $k_1$  bis  $k_3$ . Die zwei daraus resultierenden Abschnitte werden jeweils mit einem kubischen Polynom beschrieben, siehe Formel (6.8).

$$P_i(t) = c_{S,1,i} \cdot t^3 + c_{S,2,i} \cdot t^2 + c_{S,3,i} \cdot t + c_{S,4,i} \quad (6.8)$$

Beide Abschnitte sind über die Randbedingung der Stetigkeit am Knotenpunkt  $k_2$  miteinander gekoppelt:  $P_1(k_2) = P_2(k_2)$ .

Zusätzlich sind zwei separate Randbedingungen definiert. Abschnitt eins ist monoton steigend:  $P'_1(t) > 0$ . Die Steigung des zweite Spline-Abschnitt ist demgegenüber monoton fallend:  $P'_2(t) < 0$ .

Der Kennwert  $K_{\text{E,Spline}}$  des Spline-Modells wird abschließend aus den Residuen des Regressionsmodells und dem normierten Messsignal berechnet.

$$K_{\text{E,Spline}} = \frac{1}{f_{\text{Abtast}}} \cdot \sqrt{\sum (\dot{\phi}(t) - S_{\text{E}}(t))^2} \quad (6.9)$$

---

<sup>168</sup> Vgl: Benderius, O.; Markkula, G.: Bell-Shaped Steering Corrections (2014), S. 887.

### Normierung der Kennwerte

Aufgrund der bereits erfolgten Normierung des Rollratensignals auf den Bereich [0 1] repräsentieren die mittels Regressionsmodellen berechneten Kennwerte keine physikalischen Größen. Für die Vergleichbarkeit der Kennwertverteilungen der unterschiedlichen Verfahren  $i$  wird eine Normierung basierend auf dem Mittelwert und der Standardabweichung der Gesamtverteilungen der Kennwerte  $K_{E,i}$  gemäß Formel (6.10) durchgeführt. Die für die Normierung genutzten Mittelwerte und Standardabweichungen der Kennwerte sind in Tabelle C-3 im Anhang enthalten.

$$K_{E,i,\text{norm}} = \frac{K_{E,i} - \mu(K_{E,i})}{\sigma(K_{E,i})} \quad (6.10)$$

Die Kennwerte der Segmente bzw. Manöver-Primitive bei denen das Motorrad aufgerichtet wird führen den Index A (Aufrichten) anstelle E. Die Berechnungsvorschrift zum Ermitteln der Kennwerte ist identisch.

## 6.3 Zwischenfazit

Die Ergebnisse aller Verfahren sind in Abbildung 6-3 dargestellt. Deutlich zu erkennen ist, dass die Gruppe der Vielfahrer von den verbliebenen drei Gruppen mit nahezu jedem Kennwert unterschieden werden kann. Bei einer Stichprobengröße von  $N_{\text{Seq}} \approx 50$  können Vielfahrern und Fahranfänger mit einer Irrtumswahrscheinlichkeit von  $\leq 5\%$  unterschieden werden<sup>169</sup>. Unterschiede zwischen Fahranfängern und den zwei Gruppen mit mehr Fahrerfahrung können nur durch größere Stichproben und für die regressionsbasierten Kennwerte nachgewiesen werden. Der notwendige Stichprobenumfang beträgt in dem Fall  $N_{\text{Seq}} > 100$ , um Irrtumswahrscheinlichkeiten von  $\leq 10\%$  zu erzielen.

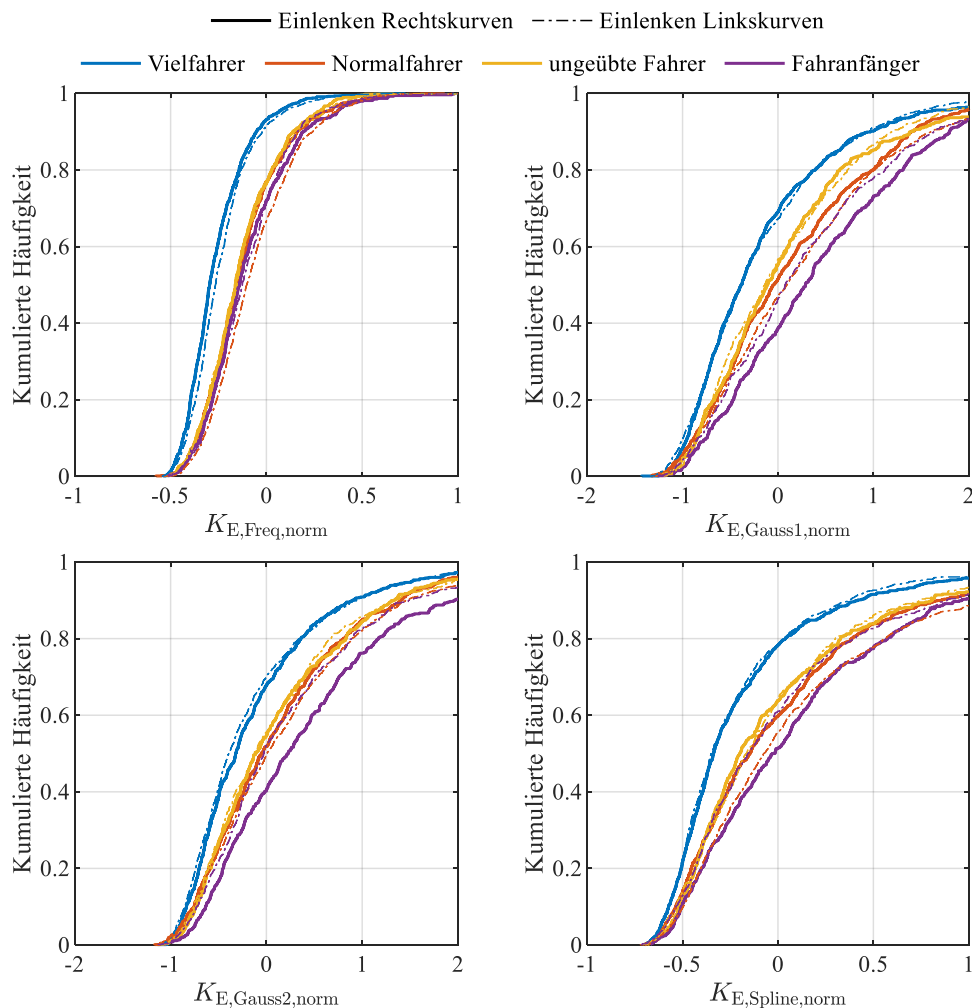


Abbildung 6-3: Verteilung der Kennwerte zur Bewertung dynamischer Einlenkvorgänge

<sup>169</sup> Getestet mit Zwei-Stichproben Kolmogorov-Smirnov Hypothesentest, da die Daten-Häufigkeitsverteilung nicht einer Normalverteilung entspricht.

Bei der Auswertung der Bewertungen der Aufrichtvorgänge am Ende der Kurvenfahrt, siehe Abbildung C-5. im Anhang, wird beobachtet, dass Vielfahrer von dem Rest der Gruppen unterscheidbar sind. Die Schwankungen innerhalb der verbliebenen drei Gruppen sind fahrerindividuell jedoch so groß, dass keine statistisch signifikanten Unterschiede zwischen den Verteilungen festgestellt werden können. Selbst bei Stichprobenumfängen von  $N_{\text{Seq}} = 200$  liegt die Irrtumswahrscheinlichkeit des Kolmogorov-Smirnov-Hypothesentest bei  $\geq 20\%$ . Zudem fällt auf, dass die Reihenfolge der Kennwertverteilungen nicht geordnet ist, d.h. Fahranfänger weisen Kennwertverteilungen mit niedrigeren Median auf als die Gruppe aus Normalfahrern. Der Aufrichtvorgang aus der stationären Kurvenfahrt in die Geradeausfahrt ist mit den definierten Kennwerten damit nicht geeignet für die Bewertung des Fahrfertigkeitsniveaus.

### Zusätzliche Normierung der Kennwerte anhand der Rollwinkeländerung

Yoneta et al. bestimmen im Rahmen ihrer Methode zur Bewertung von Abbiegevorgängen den Quotienten aus hochfrequente Rollbewegung und niederfrequenten Änderungen und leiten daraus die Informationen über den Fahrer ab<sup>170</sup>. Davon ausgehend wurde untersucht, inwiefern die Normierung der Kennwerte<sup>171</sup> durch die beim Einlenken vorgenommene Rollwinkeländerung  $\Delta\varphi$  Einfluss auf die Trennbarkeit der Fahrer hat. Die Ergebnisse zeigt Abbildung 6-4.




Abbildung 6-4: Verteilung der Kennwerte zur Bewertung dynamischer Einlenkvorgänge bei zusätzlicher Normierung der Kennwerte auf die Rollwinkeländerung während des Einlenkvorgangs

<sup>170</sup> Vgl. Yoneta, K. et al.: Offenlegung Motorcycle Rider Assessment Device (2010), S. 12ff.

<sup>171</sup> Frequenzkennwert und Regressionskennwert anhand der Glockenkurve.



Die Gruppe bestehend aus Normalfahrern und ungeübten Fahrer ist anhand der Verteilung der frequenzbasierten Kennwerte nun ebenfalls von Fahranfängern und Vielfahrern abgrenzbar. Auch für das regressionsbasierte Verfahren mit einer Glockenkurve verbessert sich die Trennbarkeit der beiden Gruppen von Normalfahrern gegenüber den Fahranfängern. Demgegenüber verschlechtert sich indes die Differenzierbarkeit von Vielfahrern gegenüber Normalfahrern.

Bei genauerer Analyse der Kennwerte über dem Rollwinkel zeigt sich gleichwohl, dass kein Unterschied in den Mittelwerten in dem Rollwinkelbereich existiert, in dem von Normalfahrer und Fahranfängern gleichermaßen Daten existieren. Die Gesamtverteilung wird einzig und alleine dadurch beeinflusst, dass Kennwerte, die bei einem höheren Rollwinkel erzielt wurden, einen „Bonus“ erhalten. Dies ist aufgrund der vorangegangenen Normierung der Rollratensignale nicht notwendig und würde die Bewertung der „Glätte“ bzw. Regelgüte des Einlenkvorgangs verfälschen.

Die zusätzliche Normierung wird daher nicht als sinnvoll erachtet und dementsprechend nicht angewendet.

Die gezeigten Ergebnisse falsifizieren weder Hypothese H4.1 noch H4.2. Die beiden regressionsbasierten Kennwerte eignen sich jedoch besser, um Fahrfertigkeiten zwischen Fahrern zu quantifizieren. Dies gilt ausschließlich für den Einlenkvorgang, nicht für das Aufrichten aus der Kurvenfahrt heraus. Insgesamt können die Erkenntnisse wie folgt zusammengefasst werden:

*Die Häufigkeitsverteilung des Approximationsfehlers für Einlenkvorgänge mit einer Glockenkurve kann als Maß zur Identifizierung unterschiedliche Fahrfertigkeitsniveaus herangezogen werden. Verteilungen mit niedrigere Kennwerten sprechen dabei für ein höheres Fahrfertigkeitsniveau.*

---

## 7 Bewertung der Klassifikation fahrer-individueller Fahrfertigkeitsniveaus

In den vorangegangenen Kapiteln wurden Methoden und Metriken zur Bewertung der einzelnen Phasen der Kurvenfahrt vorgestellt, welche die Basis zur Klassifikation der fahrerindividuellen Fahrfertigkeits darstellen. Dabei wurde gezeigt, dass mit den Kennwerten für die stationäre als auch nicht-stationäre Kurvenfahrt fehlerbehaftete von fehlerfreien Sequenzen unterschieden werden können. Es wurde ebenfalls nachgewiesen, dass die statistische Verteilung der Kennwerte der Sequenzen, mit der subjektiven Einordnung der Probanden gemäß ihrer Fahrerfahrung korreliert, was die Hypothesen bestätigt, dass die Kennwerte fahrfertigkeitsrelevante Eigenschaften messen.

In dem nun folgenden Abschnitt wird die zentrale Forschungsfrage untersucht:

*Wie differenziert sind die Fahrfertigkeit einzelner individueller Fahrer in Kurvenfahrt im Realverkehr bestimmbar?*

Dies umfasst zwei Aspekte: Zum einen, welche konkrete Kategorisierung des Fahrfertigkeitsniveaus mit der Kombination der zuvor definierten Kenngrößen für individuelle Fahrer möglich ist. Zum anderen, welcher Stichprobenumfang für eine zuverlässige Klassifikation benötigt wird.

Die Bewertung der Klassifikationsmöglichkeit umfasst ebenfalls die kritische Reflektion der zuvor verwendeten Referenzgruppierung der Fahrer vor dem Hintergrund, dass die darin abgebildete Fahrerfahrung nicht in jedem Fall mit Fahrfertigkeiten gleichzusetzen ist bzw. diese nicht daran quantifiziert werden kann.

Zur Beantwortung der Frage, welche konkrete Kategorisierung der Fahrfertigkeitsniveaus möglich ist, werden die Kennwertverteilungen separat analysiert, diskutiert und eine Zuordnung der Daten zu einer unterschiedlichen Anzahl an Fahrfertigkeitsniveaus definiert. Damit wird ebenfalls vermieden, dass durch eine pauschale, aber mit Unsicherheiten verbundene Annahme der Fahrfertigkeiten eines Fahrers, die Untersuchung des notwendigen Stichprobenumfangs negativ beeinflusst wird.

Aufbauend auf der definierten Zuordnung der Kennwertverteilungen zu Fahrfertigkeitsniveaus wird mittels einfacher Klassifikationsverfahren untersucht, welcher Stichprobenumfang notwendig ist, um eine stabile Zuordnung gewährleisten zu können. Im selben Schritt wird auf die Wahl der für die Klassifikation verwendeten Fahrfertigkeitsindikatoren der Kennwertverteilungen eingegangen und analysiert, wie sich deren Kombination auf die Klassifikationsgüte auswirkt.

## 7.1 Untersuchungsmethodik

### 7.1.1 Zufallsexperiment zur Datengenerierung

Die Ergebnisse aus Kapitel 5. und 6. zeigen, dass die Fahrergruppen nicht anhand einzelner Kennwerte, sondern nur an deren statistischer Verteilung unterscheidbar sind. Folglich gilt die Vermutung, dass dies ebenfalls bei Unterscheidung fahrerindividueller Fertigkeiteniveaus der Fall ist. Zur Untersuchung sowohl der Anzahl der klassifizierbaren Fahrfertigkeiteniveaus als auch der Betrachtung des notwendigen Stichprobenumfangs wird daher das folgende Vorgehen gewählt:

Aus dem Gesamtdatensatz von Kurvenfahrten eines jedes Probanden wird eine zufällige Stichprobe mit vorgegebenem Umfang unter der Beachtung von zuvor definierten Randbedingungen, wie z.B. nur Rechts- oder nur Linkskurven, gezogen.

Basierend auf der zufälligen Stichprobe der Kurvenfahrten wird eine Anzahl von  $N_{\text{Ind}}$  Indikatoren aus den fahrerindividuellen Kennwertverteilungen für eine bestimmte Phase der Kurvenfahrt bestimmt. Als Indikator wird dabei eine statistische Größe wie der Mittelwert oder der zu einem bestimmten Perzentil dazugehörige Kennwert der Verteilung bezeichnet. Alternativ kann ein Indikator als die zu einem Schwellwert gehörige relative Häufigkeit bzw. Wahrscheinlichkeit definiert sein, z.B. im Fall der Fahrfehlerdetektion.<sup>172</sup> Als ergänzende Merkmale für die Klassifikation können Informationen aus den Metadaten der Kurvenfahrten genutzt werden, wie z.B. die zugehörige Rollwinkelverteilung. Da es sich hierbei um statistische Kenngrößen handelt, werden diese im weiteren Verlauf der Arbeit ebenfalls als Indikatoren bezeichnet.

Dieses Vorgehen wird für jeden Probanden insgesamt  $W$ -mal wiederholt, sodass am Ende  $W$ -Stichproben bzw. deren dazugehörige Indikatoren vorliegen, die in einer Matrix  $I^{W \times N_{\text{Ind}}}$  zusammengefasst werden.

Auf diese Art und Weise werden unterschiedlichste Kurvenkombination inkl. der dazugehörigen Kennwerte unter der Beibehaltung der fahrerindividuellen statistischen Eigenschaften simuliert. Um die verschiedenen Variationen (Stichprobengröße als auch Kombination der Indikatoren) zwischen den einzelnen Experimenten vergleichbar zu halten, wird für die Stichprobenziehung der Zufallszahlengenerator in allen Fällen mit dem gleichen Startwert initialisiert.

---

<sup>172</sup> Siehe auch Erklärung am Ende des Abschnitts 5.3.3

## Randbedingungen der Stichprobenziehung

Zur Minimierung von Einflüssen aus einer möglichen fehlerhaften Segmentierung und für eine bessere Vergleichbarkeit der Ergebnisse werden beim Ziehen der Zufallsstichproben ausschließlich Segmente untersucht, die folgenden Randbedingungen erfüllen:

1. Minimale Sequenzdauer  $t_{\text{Seq}} \geq 1.0 \text{ s}$
2. Minimaler Rollwinkel  $|\varphi_{\text{Seq,max}}| \geq 15^\circ$  bzw. minimale Rollwinkeländerung  $|\Delta\varphi_{\text{Seq}}| > 10^\circ$  während des Einlenkvorgangs.

Damit reduziert sich der Evaluationsdatensatz in geringem Ausmaß abhängig vom fahrspezifischen Geschwindigkeitsverhalten. Konkret bedeutet dies, dass für Fahrer mit hohen Kurvengeschwindigkeiten und damit tendenziell kürzeren stationären Kurvenfahrten, im Minimalfall nur Sequenzen von 65 unterschiedlichen Kurven enthalten sind. Für Fahrer mit geringeren Kurvengeschwindigkeiten sind hingegen bis zu 75 der 100 Kurvenfahrten enthalten. Da die Bedingung bei der Ziehung der Stichproben aller Fahrer gilt, hat dies zur Konsequenz, dass die Kennwertverteilungen zu minimal höheren Werten parallel verschoben sind.

### 7.1.2 Diskriminanzanalyse

Basierend auf den Fahrfertigkeitsindikatoren der Kennwertverteilungen, die in der Matrix  $I$  zusammengefasst sind, und der zu jeder Stichprobe miterfassten Zuordnung zu den Fahrfertigkeitsniveaus, gleichbedeutend mit einem Label, wird eine lineare Diskriminanzanalyse<sup>173</sup> durchgeführt. Die Diskriminanzanalyse erfolgt implizit beim Training des Klassifikators zur Prädiktion des Fahrfertigkeitsniveaus anhand der Indikatoren und Rollwinkelverteilung. Konkret bedeutet dies, dass während des Trainingsschritts der  $N_{\text{Ind}}$  dimensionale Merkmalsraum mit sogenannten Diskriminanz-Hyperebenen zerlegt wird, um die Klassen bestmöglich zu separieren.<sup>174</sup>

Die Auswertung der Klassifikationsergebnisse erfolgt mittels des Leave-One-Out-Kreuzvalidierungsverfahren. Dabei wird der Datensatz in fünf gleich große Teilmengen zerlegt, um ein unabhängiges Testen zu gewährleisten. Die fünf Testdurchläufe werden dabei so durchgeführt, dass jede Teilmenge genau einmal zur Validierung verwendet wird, während der Trainingsdatensatz aus den übrigen vier Teilmengen besteht. Das Klassifikationsergebnis des Gesamtdatensatz wird aus den Ergebnissen der Durchläufe gemittelt.

---

<sup>173</sup> Fisher, R. A.: Diskriminanzanalyse (1936).

<sup>174</sup> Vgl. Runkler, T. A.: Data Mining (2010), S. 91–93.

Mit den Klassifikationsergebnissen der verschiedenen Iterationen über die Stichprobengröße kann abgeschätzt werden, welche Stichprobengröße für die Klassifikation des Fahrfertigkeitsniveaus notwendig ist, um eine bestimmte Irrtumswahrscheinlichkeit zu gewährleisten. Dies alles steht unter der Annahme, dass die Trainingsdaten den korrekten und „wirklichen“ Fahrfertigkeitsniveau zugeordnet sind. Die Auswertung der klassenspezifischen Treffergenauigkeit, für die verschiedenen Modelle mit einer unterschiedlichen Anzahl an Fahrfertigkeitsniveaus, sollte im Quervergleich Rückschlüsse zulassen, welche der getroffenen Fahrfertigkeitszuordnungen im Realverkehr realisierbar sind.

### **Alternative zur überwachten Analyse mit annotierten Daten**

Die Untersuchung des notwendigen Stichprobenumfangs für eine konsistente Klassifizierung der Fahrfertigkeit ist grundsätzlich auch mittels Clusteranalyse denkbar, denn die Clusteranalyse hat die Aufgabe „Objekte eines unklassifizierten Merkmalsdatensatzes einer bestimmten Anzahl von Clustern zuzuordnen“<sup>175</sup>. Dafür muss ein zu der Datenstruktur passender Algorithmus und ein Distanzmaß definiert werden, da diese beiden Faktoren maßgeblich das Ergebnis beeinflussen. Wenn allerdings die Wahl von Distanzmaß und Algorithmus bereits so viel Wissen und implizite Annahmen benötigt, dass ein gewünschtes Ergebnis erzielt wird, so kann dieses Wissen auch in überwachte Verfahren wie die Diskriminanzanalyse fließen, z.B. in Form einer vorherigen Einteilung der Fahrer.

Allerdings wird die manuelle Zuteilung der Stichproben zu Fahrfertigkeitsniveaus mit einer zunehmenden Anzahl an Stufen immer schwerer. Aus diesem Grund wird ab einer Anzahl von mehr als fünf Fahrfertigkeitsstufen der notwendige Stichprobenumfang für eine konsistente Fahrerklassifizierung mittels Clusteranalyse abgeschätzt.

### **7.1.3 Clusteranalyse**

Unter der gegebenen Voraussetzung von sich stark überlappenden individuellen Kennwertverteilungen bieten sich Bottom-Up-Verfahren der hierarchischen Clusteranalyse an. Jeder Datenpunkt repräsentiert dabei zu Beginn des Verfahrens ein eigenes Cluster. Iterativ werden die Daten entsprechend ihrer Distanz zueinander sowie dem gewählten Fusionsverfahren zusammengefasst, sodass eine hierarchische Baumstruktur entsteht.

Die Daten werden entsprechend des in Kapitel 7.1.1. definierten Verfahren generiert. Da die Kennwerte kardinalskaliert sind, folgt daraus, dass es die statistischen Indikatoren der Verteilungen ebenfalls sind. Somit kann die standardisierte euklidische Distanz zwischen zwei Datenpunkten berechnet werden. Dies wiederum ist Voraussetzung für die gewählte

---

<sup>175</sup> Vgl. Runkler, T. A.: Data Mining (2010), S. 105.

Fusionsmethode nach dem Verfahren von Ward<sup>176</sup>. Das Verfahren vereint jene zwei Cluster der Reihe nach, die zu einer minimalen Zunahme der Varianz des Clusters, auch Binnenvarianz genannt, führen. Das Verfahren hat sich in einer Reihe von Clustering Problemen bewährt und führt i.d.R. zu kompakten und gleichmäßig besetzten Clustern.<sup>177</sup> Nachteil des Verfahrens ist der hohe Rechenaufwand<sup>178</sup>, der sich auf die durchgeführten Experimente dahingehend auswirkt, dass die Stichprobenanzahl limitiert ist.

### **Metrik zur Beurteilung der Stichprobengröße**

Da das Ergebnis der Clusteranalyse eine Gruppierung von ähnlichen Objekten ist und keine Zuordnung zu einer Klasse erfolgt, können die Metriken der Klassifikation nicht angewendet werden. Zur Bewertung, ab welcher Stichprobengröße eine konsistente Gruppierung der Fahrer möglich ist, wird folgende Annahme getroffen: Das Fahrfertigkeitsniveau eines Fahrers für einen bestimmten Kurventyp ändert sich nicht stichprobenabhängig. Das hat zur Folge, dass für alle  $W$ -Wiederholungen des oben beschriebenen Zufallsexperiments bei dem jeweils eine Stichprobe pro Fahrer und ggf. Kurventyp<sup>179</sup> gezogen wird, die Gruppierung im Idealfall identisch sein sollte.

Die Übereinstimmung zweier Gruppierungen lässt sich mit dem „Rand Index“ ( $RI$ ), siehe Formel (7.1), und dessen angepasste Version „Adjusted Rand Index ( $ARI$ )“ messen.<sup>180,181</sup> Letztere berücksichtigt zusätzlich die Anzahl der auftretenden Gruppierungen und damit die Wahrscheinlichkeit durch eine rein zufällige Aufteilung der Gruppen zu einer Übereinstimmung zu kommen.

$$RI = \frac{TP + TN}{\binom{N_{\text{Elem}}}{2}} \quad (7.1)$$

Beide Metriken beruhen darauf, die Übereinstimmung von Objektpaaren in zwei Gruppierungen auszuzählen (Formel 7.1). Dabei ist  $N_{\text{Elem}}$  die Anzahl der gruppierten Elemente,  $TP$  die Anzahl der Objektpaare die in beiden Gruppierungen derselben Partition angehören und  $TN$  die Anzahl der Objektpaare, die in beiden Gruppierungen nicht derselben Partition angehören.

---

<sup>176</sup> Ward, J. H., JR.: Hierarchical grouping (1963).

<sup>177</sup> Vgl. Kaufman, L.; Rousseeuw, P. J.: Finding Groups in Data (2009), 44ff.

<sup>178</sup> Der Rechenaufwand steigt kubisch mit der Anzahl der zu gruppierenden Stichproben.

<sup>179</sup> Rechts- und Linkskurven werden separat betrachtet.

<sup>180</sup> Vgl. Rand, W. M.: Objective Criteria for the Evaluation of Clustering Methods (1971).

<sup>181</sup> Vgl. Hubert, L.; Arabie, P.: Comparing partitions (1985).

Da im Rahmen des Zufallsexperiments insgesamt  $W$  Wiederholungen durchgeführt werden und dementsprechend für die 19 bzw. 38 Stichproben  $W$  Gruppierungen vorliegen, wird zur Beurteilung der Konsistenz der Mittelwert aller paarweisen Vergleiche herangezogen. Die Metriken zur Beurteilung der Clustering Performance werden dann wie folgt berechnet:

$$RI_{W,\text{mittel}} = \frac{1}{\binom{W}{2}} \sum_{i=1, j=2, j>i}^{i=W-1, j=W} RI_{i,j} \quad (7.2)$$

$$ARI_{W,\text{mittel}} = \frac{1}{\binom{W}{2}} \sum_{i=1, j=2, j>i}^{i=W-1, j=W} ARI_{i,j} \quad (7.3)$$

## 7.2 Definition der Fahrfertigkeitsniveaus

Zur Untersuchung, inwiefern die Fahrergruppierungen anhand der Kennwertverteilungen unterscheidbar sind, was zentrale Voraussetzung für die Bewertung der Fahrfertigkeitsniveaus darstellt, wurden die Kennwertverteilungen bisher ausschließlich gruppiert und nicht fahrerindividuell visualisiert und diskutiert.

Die erste Analyse der gruppierten Kennwertverteilungen hat gezeigt, dass Unterschiede für Rechts- und Linkskurven existieren. So wurden in Rechtskurven beispielsweise weniger häufig Rollwinkelkorrekturen beobachtet als in Linkskurven. Folglich gibt es auch fahrerindividuelle Unterschiede die bei der pauschalen initialen Fahrergruppierung nicht berücksichtigt wurden. Vor diesem Hintergrund werden die individuellen Kennwertverteilungen analysiert und die Anzahl der erzielbaren Fahrfertigkeitsniveaus abgeleitet. Das beinhaltet ebenfalls die Zuordnung der einzelnen Stichproben der Fahrer zu den jeweiligen Stufen. Die Kombination der Stichprobendaten sowie deren Klassenzuordnung repräsentieren zusammengefasst den Datensatz für die spätere Untersuchung des benötigten Stichprobenumfangs.

### 7.2.1 Rollbewegung in stationäre Kurvenfahrt

Abbildung 7-1 zeigt die Mediane der Kennwertverteilungen zufällig gezogener Stichproben für Kurvenfahrten, über dem Median der zu den Stichproben dazugehörigen Rollwinkelverteilung.<sup>182</sup> Links- und Rechtskurven werden als separate Datenquellen behandelt und dementsprechend sind zwei Stichproben pro Fahrer pro Wiederholung dargestellt. Die fahrerindividuellen Gesamtkennwertverteilungen aus denen die Stichproben extrahiert wurden, sind in Abbildung C-6 im Anhang dargestellt.

An der Verteilung ist zu erkennen, dass nicht alle Stichproben der Vielfahrer von denen der Normalfahrer abzugrenzen sind. Dennoch werden die niedrigsten Indikatoren über dem gesamten Rollwinkelbereich von Vielfahrern erzielt. Dies ist gleichermaßen für die Indikatoren der frequenzbasierten als auch der regressionsbasierten Kennwertverteilungen der Fall.

Es wird festgestellt, dass ein Anstieg der Indikatoren über dem Rollwinkel sowohl für Vielfahrer als auch für Normalfahrer vorhanden ist. Es ist auch möglich, dass dieses Phänomen durch die Ungenauigkeiten der initialen Gruppierung der Fahrer verursacht wird. Diese These wird dadurch gestützt, dass sich die Gruppe von ungeübten Fahrern mit der von Normalfahrern überlappt und nicht durch lineare Klassengrenzen separiert werden kann.

---

<sup>182</sup> Siehe auch Kapitel 7.1.1



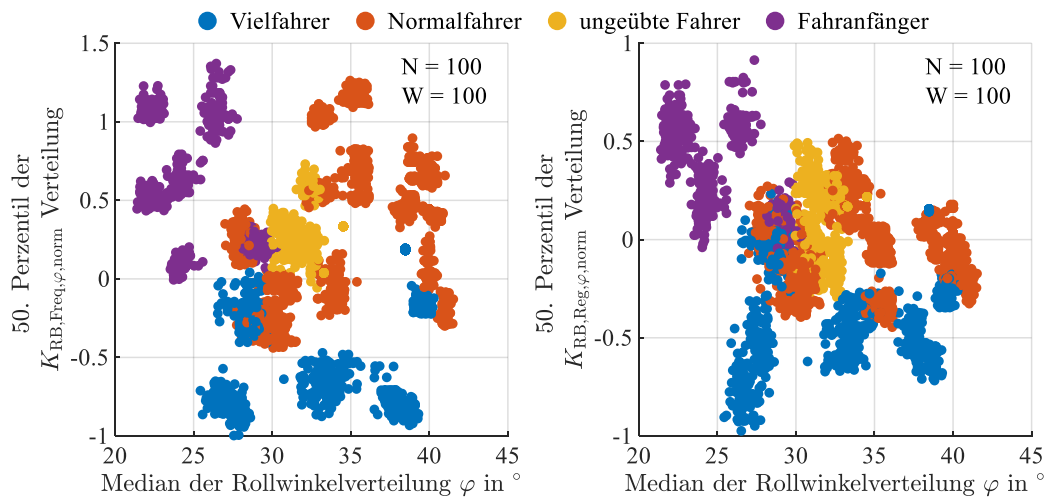


Abbildung 7-1: Streudiagramme der Indikatoren zur Bewertung der stationären Kurvenfahrt anhand der Rollbewegung. Als Indikatoren sind die Medianwerte zufällig gezogener Kennwertverteilungen genutzt. Links- und Rechtskurven sind als separate Stichproben behandelt. Pro Fahrer und Kurvenrichtung sind  $W=100$  Stichproben vom Umfang  $N=100$  dargestellt

Weiter ist ersichtlich, dass Fahranfänger in beiden Darstellungen eine Abgrenzung erfahren. Die Werte der Fahrfertigkeitsindikatoren befinden sich für diese Gruppe am oberen Skalende bei gleichzeitig geringen mittleren Rollwinkeln. Die Ausnahme ist dabei eine Stichprobe eines Fahranfängers, dessen Indikatoren für Rechtskurven denen von ungeübten und Normalfahrern ähnlich sind. Zusammen mit der Beobachtung, dass ungeübte Fahrer ebenfalls mit Normalfahrern überlappen, wird daraus gefolgert, dass anhand der quantitativen Bewertung der Kurvenfahrt mittels Kennwerte und der daraus gewonnenen statistischen Indikatoren, eine differenziertere Bewertung der Fahrer und deren Fahrfertigkeiten möglich ist.

Zusammenfassend wird festgestellt, dass die Stichproben auf Basis der Fahrfertigkeitsindikatoren der Rollbewegung gut separierbar sind. Damit ergibt sich die Möglichkeit die Fahrfertigkeitsniveaus auf unterschiedliche Weise und auch in einer unterschiedlichen Abstufung zu gruppieren.

### Definition zweier Fahrfertigkeitszuordnungen

Für die Untersuchung des notwendigen Stichprobenumfangs sowie der Klassifikationsperformance sind aufgrund der vorherigen Feststellung Modelle und Zuordnungen für drei und fünf Fahrfertigkeitsniveaus abgeleitet. Beide Zuordnungen werden als Alternative zu der ursprünglichen Fahrerklassifizierung angesehen, da diese rein auf quantitativen Daten der zuvor statistisch validierten Bewertungsmetriken beruhen.

Für eine Einordnung mit einer dreistufigen Fahrfertigkeitsskala spricht, dass damit eine robustere Klassifikation möglich ist, d.h. trotz eines geringeren Stichprobenumfangs,

häufiger die richtige Klasse zugeordnet wird. Auf der anderen Seite besitzt dies den Nachteil, dass intraindividuelle Unterschiede für Links- und Rechtskurven womöglich nicht mehr auflösbar sind, wie z.B. im Falle zuvor gemachten Beobachtung des einen Fahrers. Umgekehrt sollte die fünfstufige Skala sowohl eine größere Differenzierung zwischen den Fahrern als auch zwischen intraindividuellen Unterschieden ermöglichen.

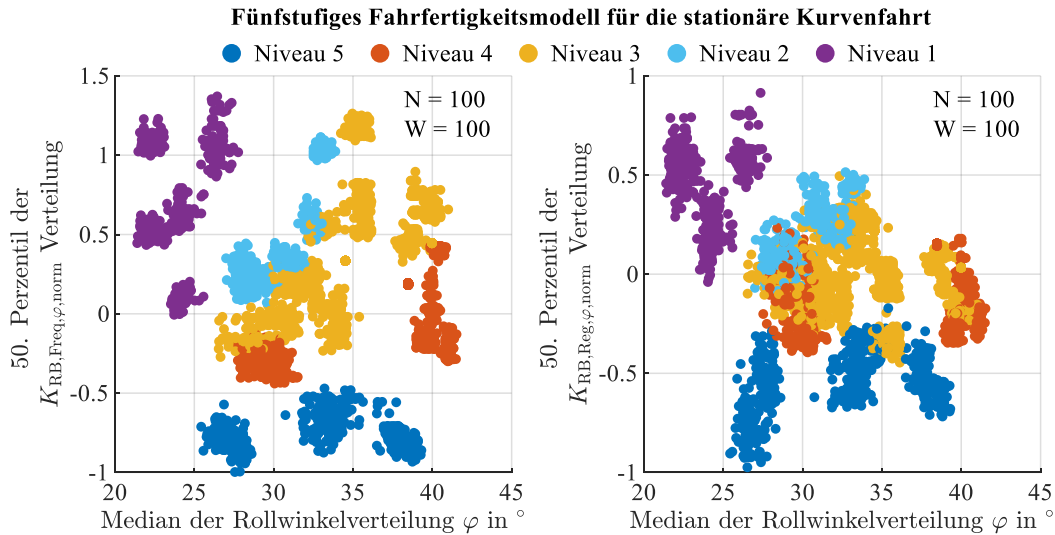


Abbildung 7-2: Fünfstufiges Modell zur Identifikation der Fahrfertigkeitsniveaus anhand der Rollbewegung in stationärer Kurvenfahrt

Die definierten Modelle, inkl. der Zuordnung der Fahrfertigkeitsniveaus zu den Stichproben für Links- und Rechtskurven sind in Abbildung 7-2 und Abbildung C-11 im Anhang gezeigt. In beiden Fällen sind die Klassengrenzen nun visuell deutlich besser unterscheidbar, sofern beide exemplarisch dargestellten Indikatoren berücksichtigt werden. Der wesentliche Unterschied besteht darin, dass ein zusätzliches Fahrfertigkeitsniveau definiert wurde, das als Zwischenstufe zwischen Vielfahrern und Normalfahrern interpretiert wird.

### 7.2.2 Fahrfehlerkorrekturen in stationärer Kurvenfahrt

Zusätzlich zur Rollbewegung in stationärer Kurvenfahrt sollten die Fahrfertigkeitsniveaus gemäß den bisherigen Erkenntnissen durch die Detektion von Fahrfehlerkorrekturmustern klassifizierbar sein. Die Analyse von zufällig generierten Stichproben einzelner Fahrer zeigt, dass dies eingeschränkt möglich ist, siehe Abbildung 7-3. Als Indikator für die Fahrfertigkeitsniveaus wird aus den Stichproben die relative Häufigkeit von Kurvenfahrten mit einem Kennwert für die Fahrfehlerdetektion von  $\geq 0,2$  extrahiert. Dieser Schwellwert ist gewählt, da in diesem Bereich die einzelnen Kennwertverteilungen der Fahrer am stärksten unterscheidbar sind, siehe Abbildung C-7 im Anhang. Wie Abbildung 7-3 veranschaulicht, sind klare Abgrenzungen der einzelnen Fahrergruppen nur bedingt erkennbar und insbesondere die Stichproben der von Normalfahrern und ungeübten Fahrern überlappen.

Dies bestätigt die Vermutung aus Abschnitt 7.2.1, dass die initiale Einteilung der Fahrer nicht 1:1 auf deren Fahrfertigkeiten übertragbar ist.

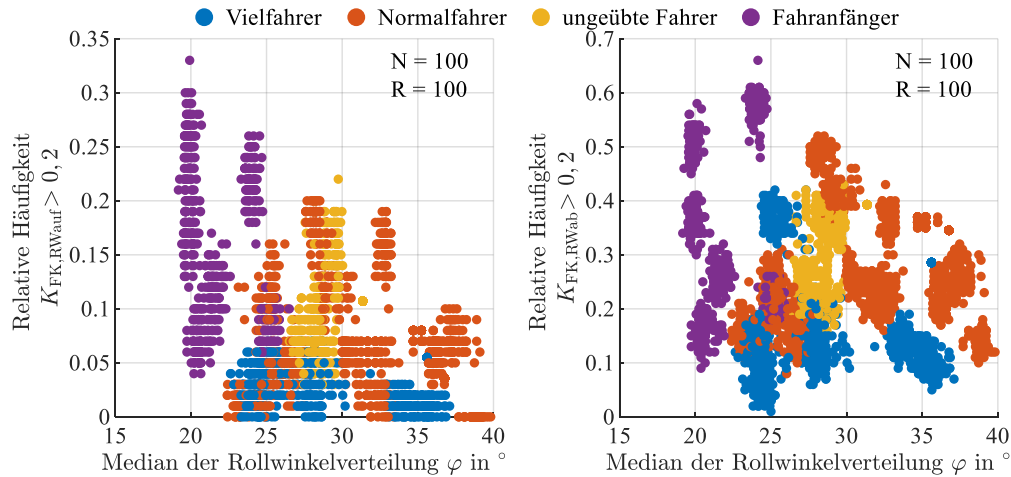


Abbildung 7-3: Streudiagramme der Indikatoren zur Fahrfertigkeitsbestimmung anhand der Fahrfehlerdetektion. Als Indikator ist die relative Häufigkeit von Kurvenfahrten mit einer Bewertung von  $K_{FK,i} > 0,2$  verwendet. Links- und Rechtskurven sind als separate Stichproben behandelt

## Definition der Fahrfertigkeitszuordnung

Für die Untersuchung des notwendigen Stichprobenumfangs wird daher eine korrigierte Zuordnung der Stichproben zu den Fahrfertigkeitsniveaus definiert. Basierend auf der Überlappung der Stichproben von Fahrern mit unterschiedlicher Fahrerfahrung sowie der modellhaften Annahme, dass die Fehlerhäufigkeit in geringem Maße mit dem Rollwinkel zunimmt, werden drei Fahrfertigkeitsniveaus identifiziert, siehe Abbildung 7-4.




Abbildung 7-4: Dreistufiges Modell zur Bewertung der Fahrfertigkeiten anhand der Fahrfehlerdetektion

Für eine Definition von bis zu fünf Fahrfertigkeitsniveaus wie in Abschnitt 7.2.1 sind die Schwankungen der Fahrfertigkeitsindikatoren der Stichproben zu groß.

Stichproben mit Indikatoren unterhalb von  $\cong 0,08$  (links) bzw.  $\cong 0,2$ , die hauptsächlich von Vielfahrern und Normalfahrern stammen, definieren das Niveau der höchsten Fahrfertigkeits. Eine zweite Gruppe, bestehend aus Strichproben von Normalfahrern bis Fahranfängern, deren Indikatoren unterhalb eines Schwellwerts von  $\cong 0,15 - 0,2$  bzw.  $\cong 0,3 - 0,4$  liegen, kennzeichnen das zweite Fahrfertigkeitsniveau. Die verbliebenen Stichproben oberhalb dieser Schwellwerte definieren das niedrigste Fahrfertigkeitsniveaus. Die Stichproben dieser Gruppe stammen bis auf eine Ausnahme von Fahranfängern.

### 7.2.3 Linienwahl in stationärer Kurvenfahrt

Abbildung 7-5 zeigt die Streudiagramme der aus den Stichproben extrahierten Indikatoren zur Bewertung der Fahrfertigkeits anhand des Trajektorienverlaufs. Als Indikatoren sind das 30. Perzentil der Positionsverschiebung zur Kurveninnenseite sowie das 70. Perzentil der Trajektorien-Welligkeit dargestellt. Die Trennbarkeit der Stichproben in diesen beiden Perzentil-Bereichen ist am höchsten, siehe hierzu Abbildung C-8 im Anhang.

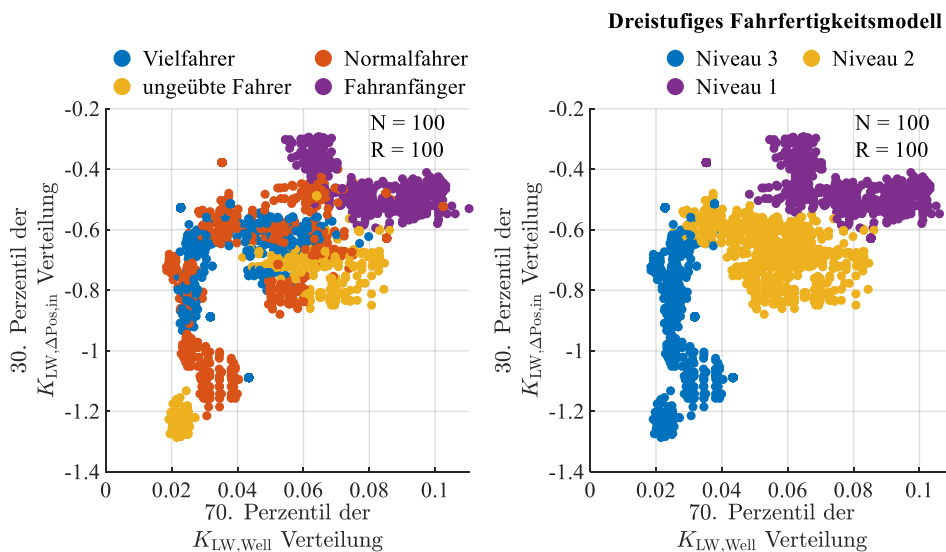


Abbildung 7-5: Streudiagramme der Indikatoren zur Fahrfertigkeitsbestimmung anhand der Linienwahl in stationäre Kurvenfahrt (rechts). Vierstufiges Modell zur Bewertung der Fahrfertigkeitsniveaus anhand der Linienwahl (links)

Auffällig ist, dass die Stichproben mit der größten betragsmäßigen Positionsverschiebung bei gleichzeitig geringer Fahrspurwelligkeit nicht von Vielfahrern erzielt werden, sondern von einer Gruppe bestehend aus Normalfahrern und ungeübten Fahrer, siehe

Abbildung 7-5 links unten. Weiterhin fällt auf, dass die Stichproben der Fahrer unterschiedlicher Erfahrung stark miteinander vermischt sind, was bereits in Kapitel 5.4 anhand Abbildung 5-17 und Abbildung 5-18 festgestellt wurde.

Da die Stichproben von Fahranfängern homogene Eigenschaften aufweisen – geringe lineare Positionsverschiebung bei gleichzeitig großen Abweichungen von einem geglätteten Verlauf – wird geschlossen, dass die Kennwertverteilungen der Linienwahl nur schwache Indikatoren für fahrerindividuelle Fahrfertigkeitsniveaus aufweisen. Insbesondere die Positionsverschiebung kann auf persönliche Präferenzen, z.B. lateralen Sicherheitsabstand zum Gegenverkehr, zurückgeführt werden.

### Abgeleitete Fahrfertigkeitszuordnung

Eine Zuordnung zu vier Klassen, wie den vier Fahrerfahrungsklassen, erscheint aufgrund dieser Argumentation sowie den gegebenen Daten nicht möglich. Eine alternative Zuordnung zu nur drei Fahrfertigkeitsniveaus ist in Abbildung 7-5 rechts dargestellt.

Ein hohes Fahrfertigkeitsniveau (Niveau 3) ist hauptsächlich dadurch gekennzeichnet, dass der Linienvverlauf in 70 % der Kurvenfahrten einer Stichprobe nur geringe Welligkeit aufweist,  $K_{LW,Well} \cong < 0,04$ . Die Positionsverschiebung ist von geringer Relevanz. Das mittlere Fahrfertigkeitsniveau, das Stichproben von Vielfahrern bis ungeübten Fahrern enthält, grenzt sich durch höhere Positionsverschiebung gegenüber den Niveau 1 und durch eine deutliche Zunahme der Positionsabweichung gegenüber Niveau 2 ab.

### 7.2.4 Rollbewegung des Einlenkvorgangs

Abbildung 7-6 zeigt die Streudiagramme der Indikatoren zur Bewertung des Einlenkvorgangs. Wie in den vorangegangenen Abschnitten korreliert die Zuordnung der Fahrerfahrung nur eingeschränkt mit den Fahrfertigkeitsindikatoren.

Die Gruppe der ungeübten Fahrer wird von Normalfahrern und Vielfahrern eingerahmt und selbst bei Kombination mehrerer Indikatoren ist keine vollständige Trennbarkeit gegeben. Dies führt zu der Schlussfolgerung, dass mit diesen Indikatoren nur drei Fahrfertigkeitsniveaus trennbar sind, in dem man Normalfahrer und ungeübte Fahrer zusammenfasst. Dies verstärkt die Hypothese, dass mehr Fahrerfahrung nicht zwangsläufig mit höheren Fahrfertigkeitsniveaus gekoppelt ist.

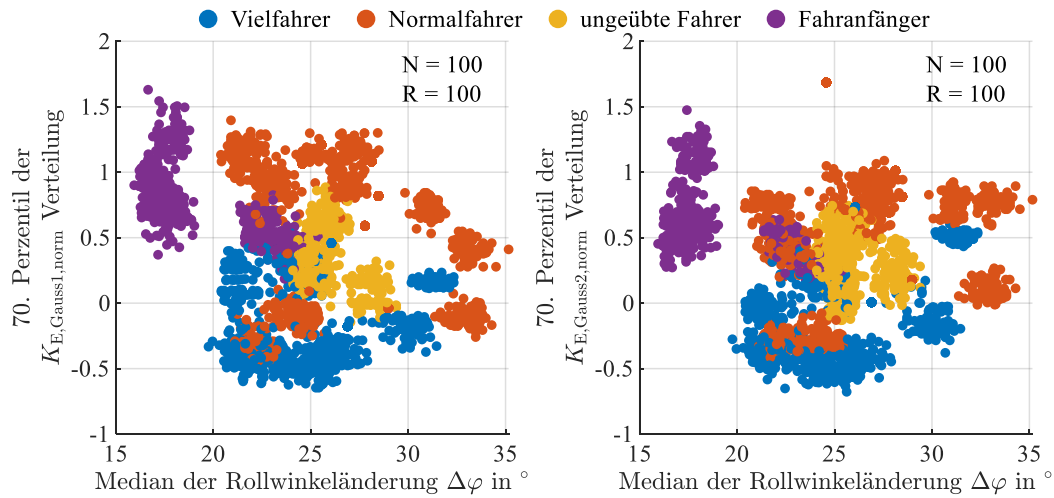


Abbildung 7-6: Streudiagramme der Indikatoren zur Fahrfertigkeitsbestimmung während des Einlenkvorgangs. Als Indikatoren sind die 70. Perzentile zufällig gezogener Verteilungen der Kennwerte verwendet. Links- und Rechtskurven sind als separate Stichproben behandelt. Pro Fahrer und Kurvenrichtung sind  $W=100$  Stichproben vom Umfang  $N=100$  dargestellt

### Abgeleitete Fahrfertigkeitszuordnung

Abbildung 7-7 zeigt die Zuordnung der Stichproben zu einem Modell mit drei Fahrfertigkeitsstufen für den Einlenkvorgang unter der Annahme, dass die zuvor gemachte Schlussfolgerungen valide ist. Das Modell berücksichtigt, dass mit größeren Rollwinkeländerung ein leichter Anstieg der Indikatoren auftreten kann.




Abbildung 7-7: Dreistufiges Modell zur Bewertung der Fahrfertigkeiten anhand der Kennwerte des Einlenkvorgangs

### 7.2.5 Reflektion der Beobachtungen

Die Analyse der individuellen Indikatorverteilungen zeigt für alle Kriterien durchgängig, dass Widersprüche zwischen der Bewertung der Fahrfertigkeitsniveaus auf Basis der Indikatoren und der Fahrereinordnung anhand der Fahrerfahrung bestehen. Die Diskrepanzen resultieren daraus, dass zwei oder mehr Stichproben, die statistisch mittels der Indikatoren nicht voneinander unterscheidbar sind, zu unterschiedlichen Fahrerfahrungs-Levels zugeordnet sind. Ebenso existieren Fälle, bei denen Stichproben eines Fahrers für Links- und Rechtskurven deutlich sichtbare Differenzen in den Mittelwerten aufweisen. Diese spiegeln sich nicht in der pauschalen Kategorisierung der Fahrerfahrung wider. Die Fahrerfahrung ist damit kein geeignetes Maß, um die Fahrfertigkeitsniveaus eines Fahrers mit Sicherheit zu quantifizieren.

Die statistischen Fahrfertigkeitsindikatoren ermöglichen hingegen eine differenzierte Auswertung der Fahrfertigkeitsniveaus eines Fahrers auch in unterschiedlichen Szenarien, wie Links- und Rechtskurven. Dass die abgeleiteten Zuordnungen der Stichproben zu den Fahrfertigkeitsniveaus in sich schlüssig sind, zeigt der Vergleich der vier unabhängigen Kriterien anhand Abbildung 7-8. Es ist erkennbar, dass die Fahrer anhand der vier Kriterien und trotz der Datenaufteilung in Links- und Rechtskurven, insgesamt konsistent bewertet sind. Dennoch ist Differenzierungspotential anhand einzelner Abweichungen vom Durchschnitt vorhanden.




Abbildung 7-8: Zuordnung der Fahrfertigkeitsniveaus auf Basis der vier Kriterien für Links- und Rechtskurven

## 7.3 Auswirkungen des Stichprobenumfangs & Indikatorenkombination

Im vorangegangenen Abschnitt wurde die Anzahl möglicher Level für die einzelnen Fahrfertigkeiten durch visuelle Analyse der Streudiagramme definiert. In diesem Abschnitt wird untersucht, wie groß die Stichprobe zur Extraktion von Fahrfertigkeitsindikatoren gewählt sein muss, um eine verlässliche Klassifikation der Fahrfertigkeiten zu erreichen. Die Auswertung erfolgt für eine unterschiedliche Anzahl und Kombination von Indikatoren, die aus den Stichproben extrahiert werden. Damit wird die Forschungsfrage untersucht:

*F1.b: Wie zuverlässig und schnell kann eine Zuordnung der Fahrfertigkeiten erfolgen?*

Aus den Ergebnissen werden zusätzlich Rückschlüsse zur Forschungsfrage des vorangegangenen Kapitels gewonnen:

*F1.a: In welcher Abstufung sind Fahrfertigkeiten differenzierbar?*

Zur Untersuchung der Auswirkung des Stichprobenumfangs und der Indikatorkombination auf das Klassifikationsergebnis wurde pro Fahrer und Kurvenrichtung  $W = 1000$  Wiederholungen des Zufallsexperiments aus Abschnitt 7.1.1 mit Stichprobenumfängen von  $N_{\text{Seq}} = 10 - 100$  durchgeführt. Basierend auf den Daten ist, sofern nicht anders beschrieben, ein Klassifikator nach dem Verfahren der Linearen Diskriminanzanalyse trainiert und das Klassifikationsergebnisse evaluiert, beschrieben in Abschnitt 7.1.2.

### 7.3.1 Identifikation des Fahrfertigkeitsniveaus anhand der Rollbewegung

Die Ergebnisse der Parametervariation für die Bewertung der Fahrfertigkeiten anhand der Rollbewegung zeigen Abbildung 7-9 bis Abbildung 7-11. Die Parameter der dargestellten Varianten sind in Tabelle 7-1 aufgeführt.

Wie in Unterkapitel 5.2 vermutet, führt die Kombination aus Indikatoren unterschiedlicher Kennwertverteilungen zu einer Verbesserung des Klassifikationsergebnisses, erkennbar in Abbildung 7-9. Werden frequenzbasierte und regressionsbasierte Kennwerte für Rollwinkel und Rollrate genutzt, verbessert sich die Treffergenauigkeit um zwei bis fünf Prozent gegenüber den Einzelvarianten. Die Kombination der Indikatoren führt insbesondere zu einer besseren Differenzierung von Niveau 2 gegenüber Niveau 1 und Niveau 3. Es wird weiter ausgemacht, dass rein anhand der Indikatoren aus den Kennwertverteilung, ohne Information über die Rollwinkelverteilung der Stichprobe, eine korrekte Fahrfertigkeiterkennung von Niveau 1 bis 3 nur in  $\cong 65 - 70 \%$  der Fälle stattfindet.



Diese Werte werden dabei bereits ab Stichproben mit einem Umfang von  $N_{\text{Seq}} = 40$  erzielt.

Tabelle 7-1: Indikatoren und Stichprobenzuordnung der untersuchten Klassifikatorvarianten (1)

Nr.:	Bezeichnung	Indikatoren (Kennwertverteilung & Perzentile)	Stichprobenzuordnung
1	RB-R(50)-5K	$K_{\text{RB,Reg},\varphi,\text{norm}}$ : Median $K_{\text{RB,Reg},\varphi,\text{norm}}$ : Median	Abgeleitetes 5. Stufen Modell, siehe Abbildung 7-2
2	RB-F(50)-5K	$K_{\text{RB,Freq},\varphi,\text{norm}}$ : Median $K_{\text{RB,Freq},\varphi,\text{norm}}$ : Median	Wie oben
3	RB-RF(50)-5K	Kombination 1 & 2	Wie oben
4	RB-RF(30,50,70)-5K	Wie 3, plus: 30. & 70. Perzentil aller Kennwertverteilungen	Wie oben
5	RB-RF(30,50,70)- $\varphi$ (50)-5K	Wie 4, plus: $\varphi$ : Median	Wie oben
6	RB-RF(30,50,70)- $\varphi$ (50)-5K-Q	Wie oben, nur quadratischer Diskriminanzanalyse	Wie oben
7	RB-RF(30,50,70)- $\varphi$ (50)-3K	Wie oben	Abgeleitetes 3. Stufen Modell, siehe Abbildung C-11,
8	RB-RF(30,50,70)- $\varphi$ (50)-OK	Wie oben	Orig. Fahrerfahrungszuordnung, siehe Abbildung 7-1

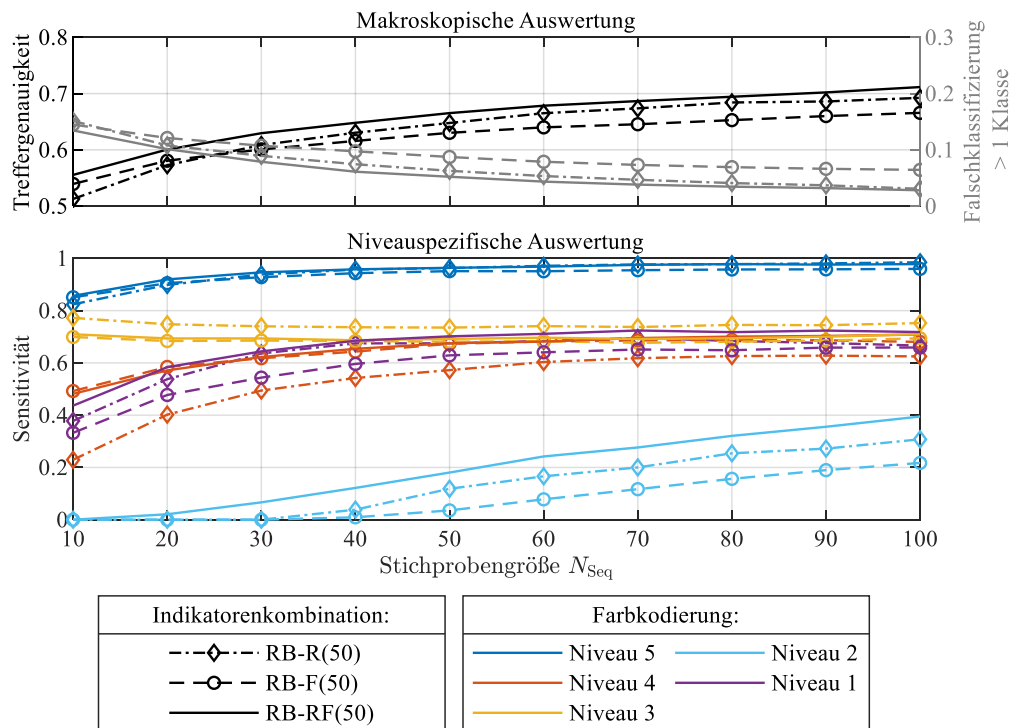


Abbildung 7-9: Stichprobenumfang zur Klassifikation der Fahrfertigkeitsniveaus anhand der Kennwerte der Rollbewegung ohne Information zur Rollwinkelverteilung

Eine weitere Zunahme der Stichprobengröße führt dazu, dass Stichproben von Niveau 2 häufiger richtig erkannt werden und nicht fälschlicherweise den benachbarten Niveaus zugeordnet. Grundsätzlich deutet dieses Verhalten daraufhin, dass die zu Niveau 2 zugeordneten Stichproben nah an der Diskriminanzhyperebene zur Trennung von Niveau 1 und 3 liegen.

### Berücksichtigung der Rollwinkelverteilung

Eine weitere Verbesserung der Treffergenauigkeit des Klassifikationsergebnisses ist durch die Verwendung von mehreren statistischen Kennzahlen der Kennwertverteilungen als Indikator möglich. Werden zusätzlich zum Median das 30. und 70. Perzentil verwendet, wird die Treffergenauigkeit um bis zu 10 % erhöht, siehe Abbildung 7-10. Allerdings können nach wie vor nur 4 der 5 Fahrfertigkeitsstufen aufgelöst werden.

Alle fünf Fahrfertigkeitsniveaus können erst bei Einbeziehung der Rollwinkelverteilung im Klassifikationsschritt und bei einer Stichprobengröße von  $N_{\text{Seq}} = 80$  mit Irrtumswahrscheinlichkeiten kleiner 20 % erkannt werden. Bei hohen Anforderungen an die Klassifikationsgenauigkeit oder einer schnellen Einschätzung der Fahrfertigkeitsstufen eines Fahrers ist eine Klassifikation in vier oder drei Stufen ratsam, siehe hierzu Abbildung 7-11. Bei nur drei Klassen ist bereits ab einer Stichprobengröße von  $N_{\text{Seq}} = 20$  eine 90 % korrekte Zuordnung möglich.




Abbildung 7-10 Stichprobenumfang zur Klassifikation der Fahrfertigkeitsstufen anhand der Kennwerte der Rollbewegung und der Rollwinkelverteilung

## Vergleich der Indikatoren-getriebenen Zuordnung der Fahrfertigkeitsniveaus gegenüber der Zuordnung auf Basis der Fahrerfahrung

Abbildung 7-11 zeigt ebenfalls das Klassifikationsergebnis, wenn die initial eingeschätzte Fahrerfahrung der Fahrer pauschal als Fahrfertigkeitsniveau der einzelnen Stichproben definiert wird. Die Treffergenauigkeit, mit der die Stichproben korrekt klassifiziert wird, liegt in diesem Fall bei 80 % für  $N_{Seq} = 100$  und damit 12 % unter jener des Fahrfertigkeitsmodells mit fünf Stufen und 15 % unter jenem mit drei Stufen.

Dies ist ein weiteres Indiz<sup>183</sup> dafür, dass Fahrerfahrung nicht gleichzusetzen ist mit Fahrfertigkeitsniveaus und die quantitative Auswertung mit den gegebenen Kennwerten eine bessere Einordnung erlaubt.




Abbildung 7-11: Gegenüberstellung der Klassifikationsgüte für unterschiedliche Zuordnung der Stichproben zu Fahrfertigkeitsniveaus.

## Quadratischer Diskriminanzanalyse

In Abbildung 7-11 ist zusätzlich eine Klassifikatorvariante dargestellt, bei der die lineare Diskriminanzfunktion zur Trennung der Klassen durch eine Quadratische ersetzt ist. Die Klassifikationsperformance wird gegenüber der linearen Variante nochmals um 10 % gesteigert. Der Grund hierfür lässt sich anhand Abbildung 7-2 nachvollziehen: Die Grenze zwischen den Stichproben benachbarter Fahrfertigkeitsniveaus ist nicht linear sondern kann wesentlich besser durch eine quadratische Funktion approximiert werden.

<sup>183</sup> kein Beweis

## Stichprobenumfang auf Basis der Clusteranalyse

Der notwendige Stichprobenumfang für eine konsistente Klassifizierung wurde ebenfalls mittels der in Unterkapitel 7.1 beschriebenen Clusteranalyse untersucht. Als Äquivalent zur Treffergenauigkeit im Falle der Klassifikationsbewertung wird bei der Clusteranalyse der mittlere Adjusted Rand Index aller paarweisen Vergleiche von zwei Iterationen des Zufallsexperiments genutzt, siehe Abschnitt 7.1.3.

Die Ergebnisse für eine verschiedene Anzahl von  $k$  Clustern sowie unterschiedlichen Stichprobenumfängen  $N_{\text{Seq}}$  sind in Abbildung 7-12 dargestellt. Die Indikatoren der Rollwinkelverteilung wurden zuvor standardisiert.<sup>184</sup>

Ab einem Stichprobenumfang von  $N_{\text{Seq}} = 60$  wird für eine Anzahl von zwei bis neun Clustern ein  $ARI_{R,\text{mittel}} \geq 0,9$  erreicht. Dies bedeutet vereinfacht gesprochen, dass die Stichproben der einzelnen Fahrer und Fahrtrichtungen in allen Iterationen des Zufallsexperiments nahezu identisch gruppiert sind.

Sofern den Clustern einzigartige Fahrfertigkeitsniveaus zugeordnet werden können, ist damit auch eine Klassifikation von mehr als fünf Fahrfertigkeitsniveaus möglich, sofern der Klassifikator bzw. Klassifikationsalgorithmus zusätzlich angepasst wird.<sup>185</sup>




Abbildung 7-12: Konsistenz der Stichprobengruppierung in Abhängigkeit der Clusteranzahl und des Stichprobenumfangs am Beispiel der Rollbewegungsindikatoren

<sup>184</sup> Notwendig, da der Cluster Algorithmus zur Berechnung der Ähnlichkeit zweier Datenpunkte das euklidische Distanzmaß verwendet und der Rollwinkel sonst gegenüber den verbliebenen Indikatoren eine zu starke Gewichtung hätte.

<sup>185</sup> Abhängig vom Clustering bzw. der Struktur der Daten.

### 7.3.2 Identifikation des Fahrfertigkeitsniveaus anhand Indikatoren aus Fahrfehlerdetektions- und Linienwahl

Abbildung 7-13 zeigt die Ergebnisse der Klassifikation der Fahrfertigkeiten anhand der Indikatoren der Fahrfehlerdetektion und der Linienwahl. Die Varianten sind in Tabelle 7-2 aufgelistet.

Mit beiden Varianten wird aus makroskopischer Perspektive eine vergleichbare Performance erzielt. Sie weisen eine Treffergenauigkeit von 90 % bei Stichprobengrößen von  $N_{\text{Seq}} = 100$  auf. Wesentliche Unterschiede werden an der Fahrfertigkeitsniveau spezifischen Auswertung sichtbar. Während die drei Niveaus anhand der Indikatoren aus der Fahrfehlerdetektion ähnlich gut klassifiziert werden können, die Schwankungsbreite liegt bei Stichproben bis  $N_{\text{Seq}} = 50$  im Bereich von fünf Prozent, ist eine deutliche Diskrepanz der niveauspezifischen Detektionsraten bei Nutzung der Fahrfertigkeitsindikatoren aus der Linienwahl festzustellen.

Das Fahrfertigkeitsniveau, das zwischen den beiden Extremen liegt, wird über den gesamten Bereich der Variation der Stichprobengröße schlechter erkannt und damit fälschlicherweise den benachbarten Stufen zugeordnet. Damit bestätigt sich die Vermutung, dass die Linienwahl, gerade im Vergleich mit den verbliebenen Kennwerten, ein schwacher Indikator für Fahrfertigkeiten im Allgemeinen ist.




Abbildung 7-13 Stichprobenumfang zur Klassifikation der Fahrfertigkeiten anhand von Fahrfehlerkorrekturen (FK) und den Kennwerten des Trajektorienverlaufs (LW)

Tabelle 7-2: Indikatoren und Stichprobenzuordnung der untersuchten Klassifikatorvarianten (2)

Nr:	Bezeichnung	Indikatoren (Kennwertverteilung & Schwellwert/Perzentil)	Stichprobenzuordnung
1	FK-F1F2(0.1,0.2,0.4)- $\varphi$ (50)-3K	$K_{FK,RW_{auf}}$ : 0.1, 0.2, 0.4 $K_{FK,RW_{ab}}$ : 0.1, 0.2, 0.4 $\varphi$ : Median	Definiertes 3. Stufen Modell, siehe Abbildung 7-4
2	LW-W(60,70,80)-V(20,30,40)-3K	$K_{LW,W_{ell}}$ : 30, 50, 70. $K_{LW,\Delta P_{os,in}}$ : 20, 30, 40.	Definiertes 3. Stufen Modell, siehe Abbildung 7-5

### 7.3.3 Klassifikation der Fahrfertigkeitsniveaus beim Einlenken

Die Klassifikation der Fahrfertigkeitsniveaus anhand der statistischen Indikatoren des Einlenkvorgangs wird in Abbildung 7-14 erläutert, die Beschreibung der Varianten ist in Tabelle 7-3 aufgeführt.

Bereits auf Basis von 30 Einlenkvorgängen können die drei Fahrfertigkeitsstufen mit einer Sicherheit von mindestens 85 % korrekt klassifiziert werden, sofern neben den statistischen Indikatoren der Kennwertverteilungen von  $K_{E,Gauss1}$  und  $K_{E,Gauss2}$  auch die Rollwinkelverteilung zur Klassifikation genutzt wird. Ohne die Information der Rollwinkelverteilung der Stichproben, sinkt die Klassifikationsgenauigkeit um fünf Prozentpunkte über alle Stichprobenumfänge hinweg ab.




Abbildung 7-14 Stichprobenumfang zur Klassifikation der Fahrfertigkeitsniveaus anhand des Einlenkvorgangs

Tabelle 7-3: Indikatoren und Stichprobenzuordnung der untersuchten Klassifikatorvarianten (3)

Nr.:	Bezeichnung	Indikatoren (Kennwertverteilung & Perzentile)	Stichprobenzuordnung
1	E-G1G2(30,50,70)-3K	$K_{E,Gauss1,norm}$ : 30, 50, 70 $K_{E,Gauss2,norm}$ : 30, 50, 70	Abgeleitetes 3. Stufen Modell, siehe Abbildung 7-7
2	E-G1G2(30,50,70)- $\varphi(50)$ -3K	Wie oben, plus Median $\Delta\varphi$	Wie oben

Der Grund hierfür ist nachvollziehbar: Bei der datengetriebenen Definition der Fahrfertigkeitslevel für den Einlenkvorgang ist eine leichte Abhängigkeit der Kennwerte vom Rollwinkel erkennbar, siehe Abbildung 7-7.

Mittels Bewertung der Rollbewegung in der stationären Kurvenfahrt werden für große Stichproben Treffergenauigkeiten von 95 % und mehr erzielt.

Die Ergebnisse der Auswertung mittels Diskriminanzanalyse legen aufgrund der guten Klassifikationsergebnisse nahe, dass die Fahrfertigkeits beim Einlenken in mehr als nur drei Niveaus unterteilbar sind. Die Auswertung der Gruppierung durch hierarchisches Clustering ist in Abbildung 7-15 dargestellt. Die Ergebnisse zeigen, dass die Daten des Einlenkvorgangs grundsätzlich weniger strukturiert sind, da die Stichproben deutlich weniger konsistent gruppiert werden können, wie dies anhand der Fahrfertigkeitsindikatoren der Rollbewegung in stationärer Kurvenfahrt der Fall ist. Damit bleibt die Frage unbeantwortet, ob eine feine gegliederte Klassifikation der Fahrfertigkeits anhand des Einlenkvorgangs möglich ist.




Abbildung 7-15: Konsistenz der Stichprobengruppierung in Abhängigkeit der Clusteranzahl und des Stichprobenumfangs für den Einlenkvorgang

## 7.4 Diskussion der Ergebnisse

Die Ergebnisse aus Kapitel 7 zeigen umfassend, dass mit der vorliegenden Segmentierung der Fahrdaten sowie den Metriken für verschiedene Phasen der Kurvenfahrt, Fahrer bezüglich ihrer Fahrfertigkeiten konsistent bewertet werden. Konsistenz wird dabei hinsichtlich zwei Aspekten erzielt: Zum einen ist das dem Fahrer zugeordnete Fahrfertigkeitslevel durch mehrere Metriken, die auf unterschiedlichen Sequenzen der Kurvenfahrt oder Messgrößen beruhen, vergleichbar bewertet. Die Abweichungen sind nur in seltenen Fällen größer als eine der direkt benachbarten Stufen. Der zweite Aspekt ist, dass das Fahrfertigkeitsniveau bei zufällig kombinierten Kurvenfahrten bei einer Stichprobengröße von zehn Sequenzen in 70 % der Fälle korrekt zugeordnet wird. Eine fehlerhafte Klassifizierung, die über das benachbarte Niveau hinausgeht, tritt nur in  $< 5$  % der Fälle auf. Mit zunehmender Stichprobengröße steigt die Treffergenauigkeit der Klassifikation auf über 95 % an, selbst bei einer Unterteilung in fünf Fertigungslevel. Die Ergebnisse werden mit einem bewährten Klassifikationsverfahren erzielt, welches gut zur Datenstruktur passt, jedoch nicht zur Überanpassung auf die Daten neigt.

Der Vergleich der verschiedenen Verfahren zeigt auch, dass die Fahrfertigkeiten am zuverlässigsten anhand der Bewertung der Rollbewegung beim Einlenken und in stationärer Kurvenfahrt klassifiziert werden. Angesichts der Statistik einzelner kurzer Rollbewegungskorrekturen sind die Fahrfertigkeiten im direkten Vergleich weniger gut zu beurteilen. Dies gilt ebenso für das Verfahren, bei dem Kennwerte aus der Fahrspur abgeleitet werden. Für letzteres liegt dies womöglich daran, dass die Wahl der Linie in Kurvenfahrt keine fertigkeitbasierte Fähigkeit ist, welche sich mit der Zeit durch wiederholtes Durchführen einer Handlung stetig verbessert. Die Linienwahl entspricht eher einer wissens- oder regelbasierten Fertigkeit oder einer persönlichen Präferenz. Dementsprechend sind die Kennwerte und Indikatoren zur Bewertung dieser Fertigkeit bzw. dieses Verhaltens stärker gestreut und benötigen einen größeren Statistikumfang für eine ebenso gute Klassifikationsperformance.

Hinsichtlich der Anzahl der unterscheidbaren Fahrfertigkeitskategorien, ist Folgendes festgestellt: Auf Grundlage der vorliegenden Daten sind Fahrfertigkeitsmodelle mit drei bis fünf Leveln definierbar, die nicht nur die Kennwertverteilungen berücksichtigen, sondern ebenfalls den Rollwinkel. Ohne die Rollwinkelinformation sind die fahrerindividuellen Stichproben schwerer zu differenzieren, was Abschnitt 7.3 bestätigt und dementsprechend auch schwerer zu gruppieren. Die Ergebnisse der Clusteranalyse zeigen, dass mittels der Fahrfertigkeitsindikatoren aus der Rollbewegung in stationärer Kurvenfahrt, aus statistischer Sicht mehr als fünf Stufen definiert werden können. Es stellt sich allerdings die Frage, für welche Applikation eine Klassifikation der Fahrfertigkeiten in eine solch hohe Anzahl an diskrete Level notwendig ist. Wie die Validität dieses Modells nach-



gewiesen werden kann, ist offen, da hierfür eine geeignete Referenzeinordnung vorhanden sein muss. Die Analyse der Fahrfertigkeitsindikatoren und der Referenzgruppierung, basierend auf der Fahrerfahrung, zeigt, dass selbst bei einer Einteilung in nur vier Fahrerfahrungsklassen Diskrepanzen zu einer quantitativen und kennwertbasierten Methode auftreten können.

---

## 8 Fazit und Ausblick

Im Rahmen dieser Arbeit ist die Möglichkeit der Fahrfertigkeitsidentifikation bei Motorradfahrern auf Grundlage von Messdaten im öffentlichen Straßenverkehr untersucht worden. Die Analyse und Diskussion der derzeit bekannten Methoden zur Fahrerbeschreibung zeigt, dass diese Modelle nicht zur Quantifizierung der Fahrfertigkeiten geeignet sind, ein spezielles Versuchsumfeld benötigen oder nicht das besonders kritische Fahrmanöver der Kurvenfahrt adressieren.

Die entwickelte Methode zur Bewertung der Fahrfertigkeiten in Kurvenfahrt unterteilt die erarbeitete Problemstellung anhand der bisherigen Erkenntnisse in drei Teile: Erstens, die automatisierte Erkennung und Zerlegung der Daten aus Kurvenfahrten des öffentlichen Straßenverkehrs in wiederkehrende, generalisierte Handlungsabläufe. Zweitens, die Definition von Metriken zur quantitativen Beschreibung der Qualität eines einzelnen Handlungsablaufs. Und drittens, die Klassifikation und Bewertung der Fahrfertigkeiten anhand statistischer Indikatoren.

Basierend auf der Zeitreihenanalyse der Rollbewegung in verschiedenen Kurvenfahrten, Modellen der Fahrzeugführung und Erkenntnissen aus Voruntersuchungen, in denen fahrerindividuelle Unterschiede während der Kurvenfahrt festgestellt wurden, ist eine Unterteilung der Fahraufgabe Kurvenfahrt in vier generalisierbare Handlungen abgeleitet. Die vier Handlungsprimitive repräsentieren das Einlenken in eine Kurve, die Stabilisierung während der stationären Kurvenfahrt, das Verlassen der Kurve sowie den Wechsel von einer in eine zweite Kurve mit unterschiedlichem Rollwinkelvorzeichen.

Die Analyse existierender Zeitreihensegmentierungsprobleme, wie z.B. in der Sprach- oder Bewegungserkennung zeigt, dass zur Segmentierung Modelle prädestiniert sind, die neben den Klassifikationsmerkmalen die sequentielle Reihenfolge der Handlungsprimitive berücksichtigen. Mit beiden untersuchten Verfahren, die im Kern auf einem Hidden-Markov-Modell basieren, wird eine Segmentierungsgüte erreicht, die den Stand der Technik ähnlicher Untersuchungen im Motorradbereich übertrifft. Es ist weiter erarbeitet, dass die Adaption der Segmentierungsmodelle an das Fahrverhalten einzelner Fahrer weiteres Potential zur Verbesserung der Zerlegung der Fahraufgabe besitzt. Beobachtet wird ebenfalls, dass die Segmentierung an den Übergängen der Handlungsprimitive nicht fehlerfrei ist. Als Konsequenz ist das Modell zur Bewertung der einzelnen Handlungsabläufe fehlertolerant gegenüber einer Fehlsegmentierung ausgelegt.

Eine weitere Erkenntnis der Evaluation der Segmentierungsmodelle ist, dass „fehlerhafte“ Handlungsabfolgen auftreten, die für eine zusätzliche Definition von weiteren

Handlungsabläufen sprechen, beispielsweise die Positionsverschiebung vor dem eigentlichen Einlenken in die Kurvenfahrt.

Die Ergebnisse belegen in Summe, dass die Segmentierung mit dem erarbeiteten Modell den Anforderungen der nachfolgenden Auswertung genügt und für weitergehende oder ähnliche Untersuchungen eine Ausgangsbasis bietet.

Der zweite Aspekt der Arbeit beschäftigt sich mit der Frage, mit welchen Kenngrößen und Verfahren zeitliche Messdatensequenzen hinsichtlich Fahrfertigkeiten bewertbar sind. Dazu sind Daten von Fahrern mit vermeintlich hoher Fahrerfahrung sowie Fahranfängern mit wenig Fahrpraxis analysiert. Es ist gezeigt, dass die Rollbewegung und der Verlauf der Fahrzeugposition innerhalb des Fahrstreifens für unerfahrene Fahrer wesentlich welliger sind als für Fahrer mit viel Fahrerfahrung. Diese „unruhigen“ Kurvenfahrten treten jedoch bei allen untersuchten Probanden auf, sodass eine Klassifikation der Fahrfertigkeit anhand weniger Kurvenfahrten nicht mit ausreichender Wahrscheinlichkeit zu einem korrekten Ergebnis führt. Mit weiteren Probandengruppen wird gleichwohl gezeigt, dass die statistische Verteilung der Kenngrößen zur Bewertung der Welligkeit des Signalverlaufs aus statistischer Sicht mit der Fahrerfahrung korreliert.

Die festgestellte Korrelation zwischen Kennwerthöhe und Fahrerfahrung bedeutet, dass die individuellen Kennwertverteilungen grundsätzlich für eine Applikation in Form eines Online-Feedback-Systems geeignet erscheinen. Beispielsweise kann eine fahrerindividuelle Rückmeldung erfolgen, wenn die zuletzt ausgewertete Kurvenfahrt oberhalb eines bestimmten Konfidenzintervalls der fahrerspezifischen Kennwertverteilung liegt.

Bei der Untersuchung der Kennwertverteilungen zur Fahrfertigkeitsklassifizierung zeigt sich, dass die Anzahl der identifizierbaren Level abhängig von dem Auswerteverfahren und der betrachteten Phase der Kurvenfahrt ist. Aus statistischen Gesichtspunkten können zwischen drei und fünf unterschiedliche Fahrfertigkeitslevel bestimmt werden. Es ist ferner festgestellt, dass bei ausreichend großer Statistik der Kurvenfahrten, fahrerindividuelle Fertigkeitsunterschiede zwischen Links- und Rechtskurven identifizierbar sind. Aus der Konsistenz der Klassifikation mittels verschiedener Kennwerte wird gefolgert, dass das Verfahren eine valide Bewertung der Fahrfertigkeiten erlaubt. Gegenüber der pauschalen Beschreibung der Fahrfertigkeiten anhand der Fahrerfahrung erlaubt die entwickelte Methode eine objektive und präziser differenzierbare Bewertung der Fahrer. Es werden ausschließlich im direkten Fahrbetrieb messbare Kenngrößen zur Eigenschaftsbewertung herangezogen anstelle unspezifischer Metainformationen wie die jährliche Fahrleistung oder der subjektiven (Selbst-) Einschätzung. Gegenüber der Fahrfertigkeitsableitung anhand des Rollwinkels stellt die entwickelte Methode gleichermaßen eine Verbesserung dar. Sie ermöglicht bei jeder Rollwinkelverteilung von Kurvenfahrten die Zuordnung zu unterschiedlichen Levels.

---

Insgesamt zeigt das Verfahren, dass die Fahrfertigkeiten zur Kurvenfahrt im realen Straßenverkehr bestimmt werden können und welche Methoden dafür geeignet sind. Damit bieten die Ergebnisse dieser Arbeit eine Ausgangsbasis für die Entwicklung einer Reihe von fahrfertigkeitsadaptiven Assistenzsystemen im Motorradbereich.

Unabhängig von der Untersuchung zur praktischen Verwendung der vorgestellten Methode eröffnen die Erkenntnisse dieser Arbeit weitere Fragestellungen:

Die erste Fragestellung betrifft die Übertragbarkeit der Ergebnisse auf andere Motorradmodelle. Im Zuge der in dieser Arbeit durchgeführten Probandenstudie wurden die Daten zur Klassifikation der Fahrfertigkeiten für alle Fahrer auf ein und demselben Fahrzeug ermittelt. Offen ist, in welcher Intensität die Fahrzeugparameter die Differenzierung der Fahrfertigkeiten beeinflussen. Ein Fahrzeug mit hohem Massenträgheitsmoment um die Rollachse oder langem Nachlauf beeinflusst die bei Fahranfängern häufiger und stärker beobachteten Rollbewegung gegebenenfalls positiv, sodass diese geringer ausfallen. Umgekehrt ist auch die Auswirkung einer erhöhten Handlichkeit des auf die Kennwerte und damit verbundene Fahrfertigkeitseinordnung unbekannt.

Ein zweiter Punkt für zukünftige Studien betrifft die vertiefte Analyse der Bewertung einzelner Kurvenfahrten bzw. Segmente der Kurvenfahrt vor dem Hintergrund, fahrerindividuelle Defizite zu identifizieren. Die im Rahmen dieser Arbeit aufgenommenen Datenmengen sind unzureichend, um statistische Auffälligkeiten, z.B. für bestimmte Kurventypen oder Rollwinkelbereiche, für die einzelnen Fahrer, sofern vorhanden, zu ermitteln. Die Frage lautet also, ob zusätzliche fahrfertigkeitsrelevante Eigenschaften und Anomalien mit größeren Datenmengen erkannt werden können. Weitere Fragestellungen können im Hinblick auf die Methoden und Verfahren zur Identifikation der Fahrfertigkeiten formuliert werden.

Die vorgestellte Methode verfolgt einen Ansatz nach dem Teile-und-Herrsche-Prinzip, bei dem die Daten sequentiell mit separaten Modellen verarbeitet und analysiert werden: der Segmentierung gefolgt von einer modellbasierten Merkmalsextraktion und dem abschließenden Klassifikationsschritt. Neue maschinelle Lernverfahren, insbesondere Tiefe Neuronale Netze, ermöglichen eine völlig neue Herangehensweise und erzielen bei einer großen Anzahl von Klassifikations-Problemstellungen den klassischen Methoden überlegene Ergebnisse. Vor diesem Hintergrund ist zu untersuchen, ob mit Ende-zu-Ende Lernverfahren bessere Klassifikationsergebnisse erzielt werden können.

Ebenfalls von Interesse ist, ob weitere bisher nicht betrachtete Fahrfertigkeitsindikatoren existieren, die wie bereits in Kapitel 4 andiskutiert, aus einer verbesserten Zerlegung der Kurvenfahrt resultieren. Ist der Lenkimpuls und oder die vorausschauende Positionierung vor einer Kurve ein weiteres Merkmal für die Fahrfertigkeit eines Fahrers? Oder lassen sich aus der vernachlässigten Sequenz der Geradeausfahrt Indikatoren ableiten?

---

## A Datenaufnahme und Vorverarbeitung

### A.1 Versuchsfahrzeug



Abbildung A-1: Versuchsmotorrad inkl. Messtechnikaufbau

Tabelle A-1: Technische Daten des Versuchsfahrzeugs

Eigenschaft	Wert
Länge	2210 mm
Breite	830 mm
Höhe	1285 mm
Radstand	1540 mm
Sitzhöhe	830 mm
Bereifung vorne	120/70-17
Bereifung hinten	160/60-17
Lenkkopfwinkel	63,0 °
Federweg vorne/hinten	154 / 150 mm
Gewicht vollgetankt	218 kg

## A.2 Video Synchronisation

Abbildung A-2 zeigt die synchronisierten Messdaten der Rollrate aus Inertialmesseinheit und Kamerabildern. Die Startpunkte der beiden Bildsequenzen liegen insgesamt 6000 Bilder auseinander. Die Differenz der über die Korrelation zugeordneten Startzeitpunkte beträgt in diesem Beispiel 100,1 Sekunden, was bei einer Bildwiederholungsrate von 59,9401 Hz exakt den zuvor genannten 6000 Bildern entspricht.




Abbildung A-2: Exemplarische Synchronisierung der Rollraten aus Inertialmesseinheit (blau) und Kamerabildern (rot und gelb)

## A.3 Berechnung der Position im Fahrstreifen

### A.3.1 Heuristik zur Zuordnung der erkannten Linien zu den Fahrstreifenmarkierungen

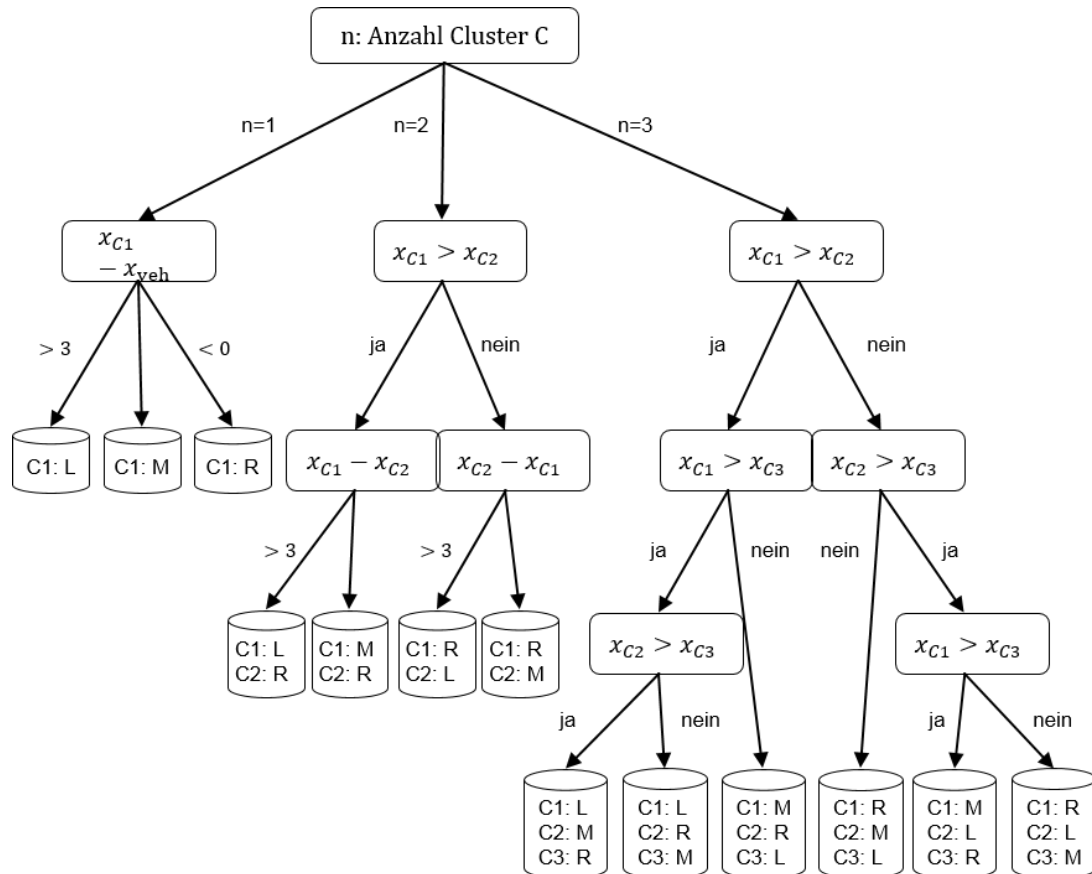


Abbildung A-3 Entscheidungsbaum für die Zuordnung der identifizierten Fahrstreifencluster zu den Fahrstreifenmarkierungen Rechts (R), Mitte (M) und Links (L)

### A.3.2 Analyse der Fahrstreifen-Positionsschätzung




Abbildung A-4: Häufigkeitsverteilung der Distanzmaße für das initiale Clustering basierend auf dem geschätzten Fahrstreifenverlauf (blau) sowie des Clustering basierend auf der Approximation des Clusters mit der größten Anzahl an zugeordneten Fahrstreifenmarkierungen (rot). Verteilung zugehörig zu Abbildung 3-4




Abbildung A-5: Häufigkeitsverteilung der Entfernung des Fahrzeugs zur rechten Fahrstreifenmarkierung



## B Messdaten Segmentierung

### B.1 Definition der Manöver-Primitive

Tabelle B-1: Auflistung definierter Manöver-Primitive.

Abk.	Nr.	Bezeichnung	Rollwinkel	Rollrate	Vorrausgehende Segmente
S	1	Geradeausfahrt	$\cong 0^\circ$	$ \dot{\phi}  < 6^\circ/s$	RO, LO
SR	2	stationäre Rechtskurve	$> 6^\circ$	$ \dot{\phi}  < 6^\circ/s$	RI, LR, (RL)
SL	3	Stationäre Linkskurve	$< -6^\circ$	$ \dot{\phi}  < 6^\circ/s$	LI, RL, (LR)
RI	4	Einlenken Rechtskurve	$0^\circ \rightarrow > 6^\circ$	$\dot{\phi} > 6^\circ/s$	S
LR	5	Wechsel Links-Rechts	unbeschränkt	$\dot{\phi} > 11^\circ/s$	SL, LI, RL
RO	6	Auslenken Linkskurve	$< -6^\circ \rightarrow 0^\circ$	$\dot{\phi} > 6^\circ/s$	SL, RL
LI	7	Einlenken Linkskurve	$0^\circ \rightarrow < -6^\circ$	$\dot{\phi} < -6^\circ/s$	S
RL	8	Wechsel Rechts-Links	unbeschränkt	$\dot{\phi} < -11^\circ/s$	SR, RI, LR
LO	9	Auslenken Rechtskurve	$> 6^\circ \rightarrow 0^\circ$	$\dot{\phi} < -6^\circ/s$	SR, LR

Bei den beschriebenen Grenzwerten für Rollwinkel bzw. Rollrate handelt es sich um Richtwerte zur Definition der Manöver-Primitive. Ein Rollwinkel von  $6^\circ$  entspricht dabei einer Querschleunigung von  $1 \text{ m/s}^2$

## B.2 Abfolge der Manöver-Primitive:

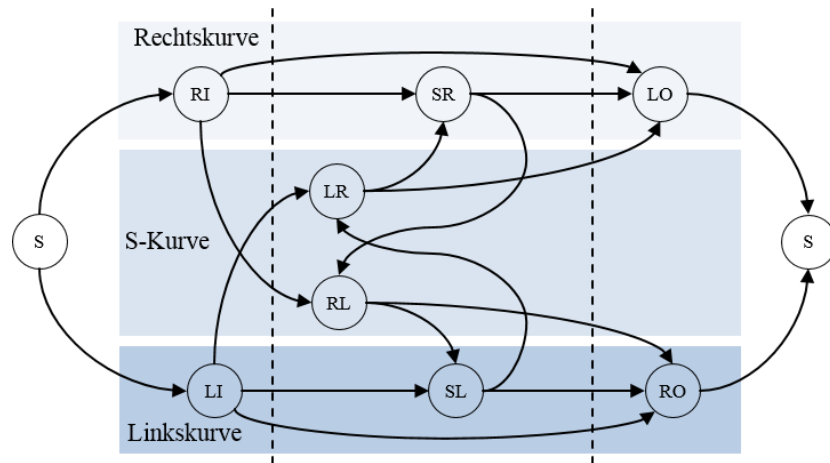


Abbildung B-1: Gerichteter Multigraph der Zerlegung in Manöver-Primitive

## B.3 Unschärfe der Segmentierungspunkte




Abbildung B-2: Häufigkeitsverteilung der Segmentierungspunkte über der Rollrate für den annotierten Messdatensatz zum Training und Validierung der Segmentierungsmodelle

## B.4 HHMM Modelparameter




Abbildung B-3: Struktur der HHMM Zustandsübergangsmatrix A

## B.5 Plausibilisierung der HMM Manöverabfolge

```

while Sequenz nicht zu Ende do
    Finde Sequenzabfolge für möglichen Falschklassifikation am
    Kurveneingang;
    if Sequenz = [S → LI → LR] ∨ Sequenz = [S → RI → RL] then
        Überprüfe ob Fehler aufgrund der vorgelagerten
        Positionverschiebung vorliegt
        if  $\Delta t(LI) < \Delta t_{\min} \vee \varphi_{\text{end}}(LR \text{ bzw. } RL) < \varphi_{\min}$  then
            ändere LI oder RI → S;
            ändere LR oder RL → RI bzw. LI;
        end
    end
    Finde Sequenzabfolge für möglichen Falschklassifikation am
    Kurvenausgang;
    if Sequenz = [RL → RO → S] ∨ Sequenz = [LR → LO → S] then
        Überprüfe ob Fehler aufgrund der Positionverschiebung nach der
        Kurvenfahrt vorliegt
        if  $\Delta t(RL \text{ bzw. } LR) < \Delta t_{\min} \vee \varphi_{\text{end}}(LR \text{ bzw. } RL) < \varphi_{\min}$  then
            ändere LR oder RL → RO bzw. LO;
            ändere RO oder LO → S;
        end
    end
end
end

```

Abbildung B-4: Pseudo-Code der Plausibilisierung der Manöver-Sequenz Abfolge zur Vermeidung fehlerhafter Klassifikation des Ein- und Auslenkvorgangs als Richtungswechsel

## B.6 Ergebnisse der Auswertung der Segmentierungsgüte

Tabelle B-2: Konfusionsmatrix HHMM Variante 1

		Referenz-MP (Annotation)									
		MP 1 S	MP 2 SR	MP 3 SL	MP 4 RI	MP 5 LR	MP 6 RO	MP 7 LI	MP 8 RL	MP 9 LO	PPV
Prädiziertes-MP (Algorithmus)	MP 1 S	7406	0	10	260	0	184	191	10	144	0,903
	MP 2 SR	0	3430	36	149	100	1	0	54	244	0,855
	MP 3 SL	0	0	3256	0	61	166	164	68	5	0,875
	MP 4 RI	413	137	0	2267	103	10	7	8	35	0,761
	MP 5 LR	22	25	49	265	1211	231	16	4	3	0,663
	MP 6 RO	302	1	124	9	117	2680	17	4	22	0,818
	MP 7 LI	465	14	147	2	4	43	2566	170	13	0,749
	MP 8 RL	17	13	100	1	6	12	276	1125	47	0,704
	MP 9 LO	310	91	1	3	1	45	8	183	2585	0,801
TPR	0,829	0,924	0,875	0,767	0,755	0,795	0,791	0,692	0,834	ACC: 0,822	

Tabelle B-3: Konfusionsmatrix HHMM Variante 4.1

		Referenz-MP (Annotation)									
		MP 1 S	MP 2 SR	MP 3 SL	MP 4 RI	MP 5 LR	MP 6 RO	MP 7 LI	MP 8 RL	MP 9 LO	PPV
Prädiziertes-MP (Algorithmus)	MP 1 S	7272	0	0	75	0	108	75	0	111	0,952
	MP 2 SR	67	3178	34	76	37	0	1	17	82	0,910
	MP 3 SL	40	0	3252	0	32	91	73	10	5	0,928
	MP 4 RI	449	222	0	2619	96	4	8	6	36	0,761
	MP 5 LR	11	39	44	161	1298	215	3	7	3	0,729
	MP 6 RO	281	0	148	9	127	2865	14	3	23	0,826
	MP 7 LI	510	7	181	3	5	35	2867	124	2	0,768
	MP 8 RL	4	28	64	5	6	24	197	1338	0	0,803
	MP 9 LO	301	237	0	8	2	30	7	121	2836	0,801
TPR		0,814	0,856	0,873	0,886	0,81	0,85	0,884	0,823	0,915	ACC: 0,866

Tabelle B-4: Konfusionsmatrix HHMM Variante 4.2

		Referenz-MP (Annotation)									PPV
		MP 1 S	MP 2 SR	MP 3 SL	MP 4 RI	MP 5 LR	MP 6 RO	MP 7 LI	MP 8 RL	MP 9 LO	
Prädiziertes-MP (Algorithmus)	MP 1 S	7185	58	78	517	16	300	465	10	306	0,955
	MP 2 SR	0	3193	0	206	44	0	3	29	236	0,917
	MP 3 SL	0	34	3296	0	43	122	151	77	0	0,918
	MP 4 RI	68	77	1	2566	219	12	2	5	6	0,747
	MP 5 LR	0	24	33	98	1287	149	3	3	6	0,697
	MP 6 RO	102	0	94	5	221	2860	34	26	30	0,819
	MP 7 LI	58	1	74	6	3	21	2799	273	10	0,784
	MP 8 RL	0	15	8	7	6	4	104	1384	98	0,766
	MP 9 LO	111	80	5	31	7	24	8	0	2832	0,804
	TPR	0,804	0,860	0,885	0,868	0,803	0,848	0,863	0,851	0,914	ACC: 0,849

Tabelle B-5: Klassenspezifische Kennwerte für SHMM  $\phi = 1^\circ$

Manöver- Primitive	MP 1 S	MP 2 SR	MP 3 SL	MP 4 RI	MP 5 LR	MP 6 RO	MP 7 LI	MP 8 RL	MP 9 LO
Sensitivität (TPR)	0,841	0,892	0,840	0,839	0,886	0,823	0,883	0,869	0,824
Relevanz (PPV)	0,959	0,881	0,892	0,866	0,686	0,812	0,779	0,679	0,837

## C Metriken zu Bewertung der Kurvenfahrt

### C.1 Impulsantwort Bandpassfilter




Abbildung C-1: Impulsantwort des Bandpassfilters zur Filterung der Rollwinkel und Rollrate stationärer Kurvenfahrt




Abbildung C-2: Impulsantwort des Bandpassfilters zur Filterung der Rollrate beim Einlenkvor-gang. Die Grenzfrequenzen sind auf die Trennung von Fahrern unterschiedlicher Fahrerfahrung optimiert

## C.2 Korrelation zw. Kennwerten und Metadaten

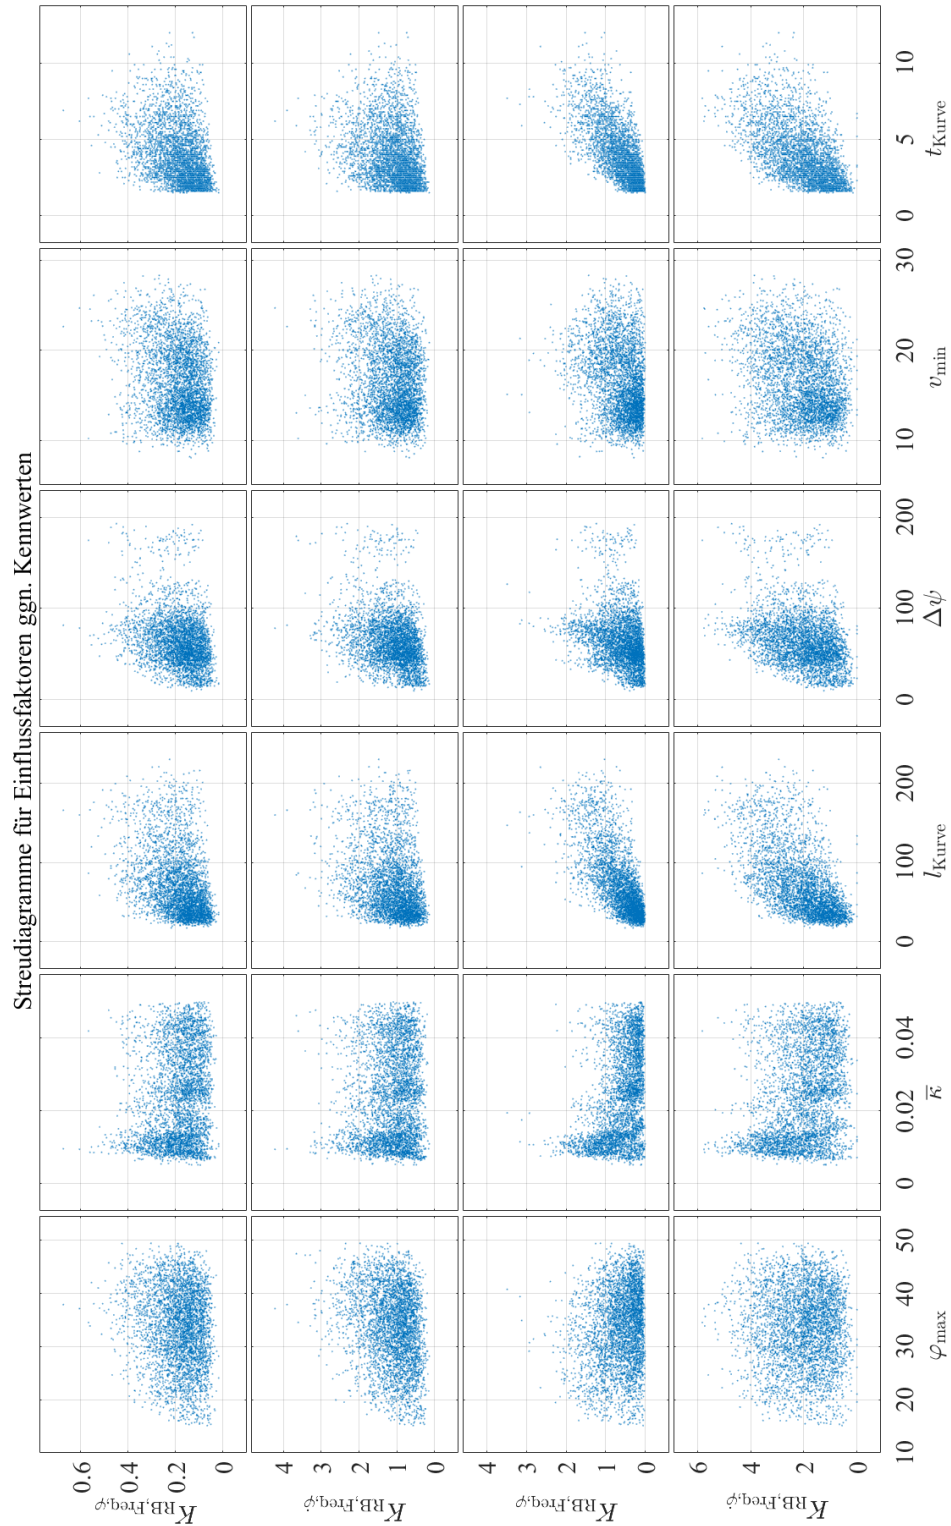


Abbildung C-3: Streudiagramme der Kennwerte für die Rollbewegung in stationärer Kurvenfahrt und möglichen Einflussfaktoren vor Skalierung und Normierung

Tabelle C-1: Parameter zur Normierung der Kennwerte der Rollbewegung in stationärer Kurvenfahrt

Kennwert	$c_{RB,korr,1}$	$c_{RB,korr,2}$	$c_{RB,korr,3}$	$c_{RB,korr,4}$	$c_{RB,korr,5}$
$K_{RB,Freq,\varphi}$	0,0042 s	-2,060 °s/m	0,0006	0,0008	0,07
$K_{RB,Freq,\dot{\varphi}}$	0,0277 s	-13,781 °/m	0,0019	0,0060	0,45
$K_{RB,Reg,\varphi}$	0,0015 s	-5,129 °s/m	0,0067	0,0035	0,26
$K_{RB,Reg,\dot{\varphi}}$	0,0318 s	-21,185 °/m	0,0108	0,0110	0,73

Tabelle C-2: Korrelationsmatrix der Kennwerte der Rollbewegung in stationärer Kurvenfahrt nach erfolgter Normierung

	$K_{RB,Freq,\varphi}$	$K_{RB,Freq,\dot{\varphi}}$	$K_{RB,Reg,\varphi}$	$K_{RB,Reg,\dot{\varphi}}$
$\varphi_{\max}$	-0,07	-0,03	-0,06	-0,07
$\bar{\kappa}$	-0,03	-0,01	-0,02	-0,03
$l_{\text{Kurve}}$	-0,02	-0,01	-0,02	-0,02
$\Delta\psi$	-0,03	-0,01	-0,03	-0,03
$v_{\min}$	-0,03	-0,02	-0,09	-0,06
$t$	-0,01	-0,01	0,03	0,00

Tabelle C-3: Parameter zur Normierung der Kennwerte der Rollbewegung für Segmente mit dynamischer Rollbewegung (Einlenken, Richtungswechsel und Verlassen der Kurvenfahrt)

Kennwertverteilung	Mittelwert $\mu$	Standardabweichung $\sigma$
$K_{E,Freq}$	0,57	0,82
$K_{E,Gauss1}$	0,60	0,39
$K_{E,Gauss2}$	0,31	0,24
$K_{E,Spline}$	0,40	0,52



### C.3 Ergebnisse der statistischen Tests der Verteilungen

Tabelle C-4: Ergebnisse des t-Test zur Untersuchung von Mittelwert Unterschieden der Kennwertverteilungen der Rollbewegung in stationärer Kurvenfahrt links

$K_{RB,Freq,\varphi,norm}$						
Stichprobengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	1,6 %	1,6 %	< 1 %	98,4 %	22,9 %	22,0 %
50	< 1 %	< 1 %	< 1 %	97,5 %	3,4 %	3,1 %
$K_{RB,Freq,\phi,norm}$						
Stichprobengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	1,2 %	< 1 %	< 1 %	88,5 %	29,2 %	32,8 %
50	< 1 %	< 1 %	< 1 %	82,0 %	7,5 %	9,4 %
$K_{RB,Reg,\varphi,norm}$						
Stichprobengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	37,8 %	36,1 %	7,3 %	91,2 %	29,8 %	40,0 %
50	11,5 %	5,8 %	< 1 %	64,3 %	3,5 %	12,9 %
$K_{RB,Reg,\phi,norm}$						
Stichprobengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	5,4 %	4,7 %	< 1 %	93,1 %	19,1 %	23,1 %
50	< 1 %	< 1 %	< 1 %	81,3 %	2,3 %	4,3 %

Die Indizes 1 bis 4 stehen stellvertretend für die Fahrergruppierung. 1: Vielfahrer, 2: Normalfahrer, 3: ungeübte Normalfahrer, 4: Fahranfänger

Tabelle C-5: Ergebnisse des t-Test zur Untersuchung von Mittelwert Unterschieden der Kennwertverteilungen der Rollbewegung in stationärer Kurvenfahrt rechts

$K_{RB,Freq,\varphi,norm}$						
Stichpro- bengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	7,9 %	9,2 %	1,7 %	86,4 %	62,0 %	47,6 %
50	< 1 %	< 1 %	< 1 %	73,5 %	42,8 %	22,2 %
$K_{RB,Freq,\dot{\varphi},norm}$						
Stichpro- bengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	3,2 %	5,9 %	< 1 %	63,2 %	79,5 %	40,8 %
50	< 1 %	< 1 %	< 1 %	36,3 %	73,5 %	15,7 %
$K_{RB,Reg,\varphi,norm}$						
Stichpro- bengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	33,0 %	19,6 %	18,6 %	71,1 %	65,8 %	93,0 %
50	7,2 %	1,7 %	< 1 %	47,3 %	28,4 %	72,6 %
$K_{RB,Reg,\dot{\varphi},norm}$						
Stichpro- bengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	5,7 %	13,2 %	2,5 %	80,2 %	71,7 %	56,4 %
50	< 1 %	< 1 %	< 1 %	83,2 %	45,3 %	35,1 %

Die Indizes 1 bis 4 stehen stellvertretend für die Fahrergruppierung. 1: Vielfahrer, 2: Normalfahrer, 3: ungeübte Normalfahrer, 4: Fahranfänger

Tabelle C-6: Ergebnisse des Kolmogorov-Smirnov-Test der Kennwertverteilungen von Fahrfehlerkorrekturen in stationäre Kurvenfahrt links

$K_{FK,RWauf}$						
Stichprobengröße N	$\alpha(V_1 \neq V_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	77,1 %	77,1 %	5,9 %	100,0 %	49,7 %	49,7 %
50	35,8 %	24,1 %	< 1 %	100,0 %	5,6 %	9,5 %
70	15,9 %	10,6 %	< 1 %	100,0 %	1,6 %	2,6 %
$K_{FK,RWab}$						
Stichprobengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	49,7 %	49,7 %	5,9 %	100,0%	77,1 %	77,1 %
50	15,5 %	9,5 %	< 1 %	100,0%	24,1 %	24,1 %
70	4,3 %	2,6 %	< 1 %	100,0%	6,9 %	6,9 %

Die Indizes 1 bis 4 stehen stellvertretend für die Fahrergruppierung. 1: Vielfahrer, 2: Normalfahrer, 3: ungeübte Normalfahrer, 4: Fahranfänger

Tabelle C-7: Ergebnisse des Kolmogorov-Smirnov-Test der Kennwertverteilungen von Fahrfehlerkorrekturen in stationäre Kurvenfahrt rechts

$K_{FK,RWauf}$						
Stichprobengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	96,5 %	77,1 %	27,5 %	100,0 %	77,1 %	77,1 %
50	50,8 %	35,8 %	< 1 %	100,0 %	35,8 %	50,8 %
90	20,7 %	10,3 %	< 1 %	98,5 %	10,3 %	14,8 %
$K_{FK,RWab}$						
Stichprobengröße N	$\alpha(\mu_1 \neq \mu_2)$	$\alpha(\mu_1 \neq \mu_3)$	$\alpha(\mu_1 \neq \mu_4)$	$\alpha(\mu_2 \neq \mu_3)$	$\alpha(\mu_2 \neq \mu_4)$	$\alpha(\mu_3 \neq \mu_4)$
20	49,7 %	49,7 %	13,5 %	100,0 %	96,5 %	96,5 %
50	15,5 %	9,5 %	<1 %	100,0 %	50,8 %	67,8 %
90	2,0 %	1,2 %	<1 %	99,9 %	20,7 %	37,6 %

Die Indizes 1 bis 4 stehen stellvertretend für die Fahrergruppierung. 1: Vielfahrer, 2: Normalfahrer, 3: ungeübte Normalfahrer, 4: Fahranfänger

## C.4 Frequenzoptimierung zur Bewertung dynamischer Rollbewegung




Abbildung C-4: Ergebnisse der Frequenzoptimierung der unteren (HP) und oberen (TP) Grenzfrequenz des Bandpassfilters zur Erkennung fehlerhafter Einlenkvorgänge mittels t-Test Statistik

## C.5 Kennwertverteilungen der Bewertung des Aufrichtens

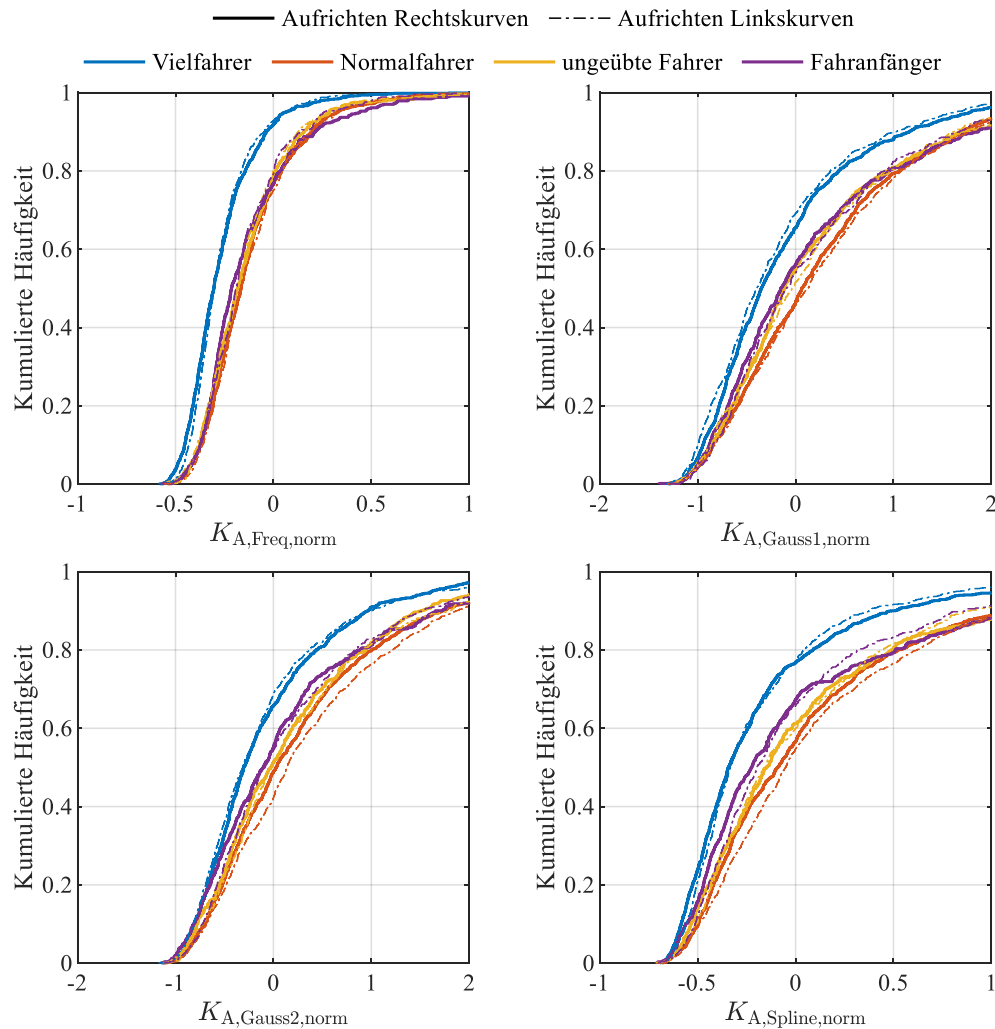


Abbildung C-5: Verteilung der Kennwerte zur Bewertung dynamischer Aufrichtvorgänge beim Verlassen der Kurvenfahrt

## C.6 Fahrerindividuelle Kennwertverteilungen

### C.6.1 Rollbewegung in stationärer Kurvenfahrt




Abbildung C-6: Fahrerindividuelle Kennwertverteilungen der Bewertung der Rollbewegung in stationärer Kurvenfahrt. Links- und Rechtskurven sind als separate Verteilungen dargestellt

## C.6.2 Fahrfehlerkorrekturen in stationärer Kurvenfahrt




Abbildung C-7 Fahrerindividuelle Kennwertverteilungen der Bewertung stationärer Kurvenfahrt anhand der Fahrfehlerdetektion. Links- und Rechtskurven sind als separate Verteilungen dargestellt

## C.6.3 Linienwahl in stationärer Kurvenfahrt




Abbildung C-8: Fahrerindividuelle Kennwertverteilungen zur Bewertung der stationären Kurvenfahrt anhand der Linienwahl. Links- und Rechtskurven sind als separate Verteilungen dargestellt

## C.6.4 Rollbewegung beim Einlenken




Abbildung C-9: Fahrerindividuelle Kennwertverteilungen der Bewertung des Einlenkvorgangs in Kurvenfahrt. Links- und Rechtskurven sind als separate Verteilungen dargestellt



## C.6.5 Rollwinkelverteilung




Abbildung C-10: Fahrerindividuelle Rollwinkelverteilung. Links- und Rechtskurven sind als separate Verteilungen dargestellt

## C.6.6 Dreistufiges Fahrfertigkeitsmodell für die stationäre Kurvenfahrt

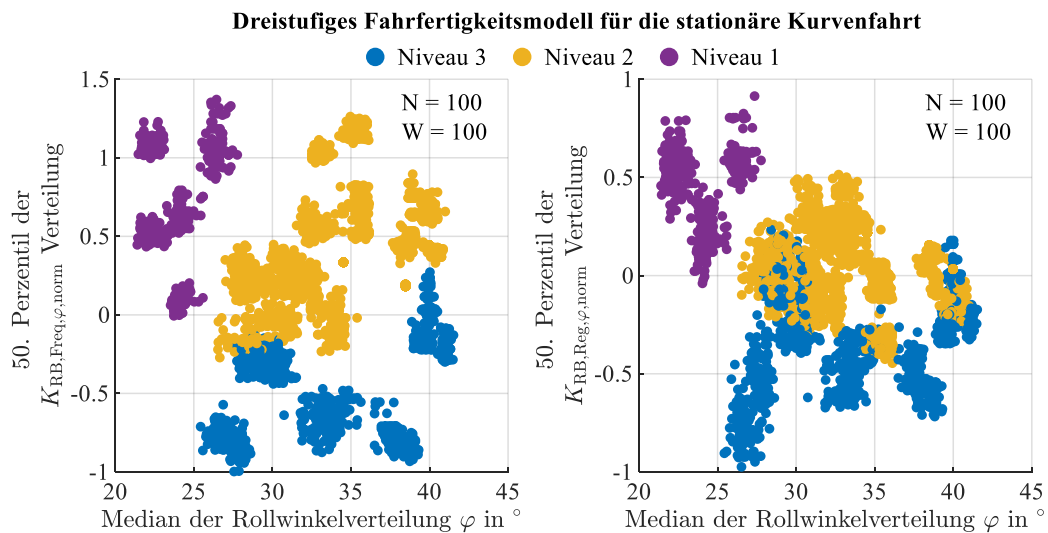


Abbildung C-11: Dreistufiges Fahrfertigkeitsmodell für die stationäre Kurvenfahrt. Abgeleitet aus den Kennwertverteilungen der Rollbewegung sowie den Informationen der Probandenstudie

## Literaturverzeichnis

**Alex Kendall et al.: Bayesian SegNet: Model Uncertainty in Deep Convolutional Encoder-Decoder Architectures for Scene Understanding (2015)**

Alex Kendall; Vijay Badrinarayanan; Roberto Cipolla: Bayesian SegNet: Model Uncertainty in Deep Convolutional Encoder-Decoder Architectures for Scene Understanding, in: CoRRabs/1511.02680, 2015

**Atkeson, C. G.; Hollerbach, J. M.: Kinematic features of unrestrained vertical arm movements (1985)**

Atkeson, C. G.; Hollerbach, J. M.: Kinematic features of unrestrained vertical arm movements, in: The Journal of Neuroscience (9), Jahrgang 5, S. 2318–2330, 1985

**Attal, F. et al.: Riding Pattern Recognition for PTW (2013)**

Attal, Ferhat; Boubezoul, Abderrahmane; Oukhellou, Latifa; Espie, Stephane: Riding patterns recognition for Powered two-wheelers users' behaviors analysis, in: 2013 16th International IEEE Conference on Intelligent Transportation Systems - (ITSC 2013), 2013

**Bay, H. et al.: SURF: Speeded Up Robust Features (2006)**

Bay, Herbert; Tuytelaars, Tinne; van Gool, Luc: SURF: Speeded Up Robust Features, in: Leonardis, Aleš; Bischof, Horst; Pinz, Axel (Hrsg.): Computer vision-- ECCV 2006, Lecture notes in computer science 3951-3954, Springer, Berlin, New York, 2006

**Benderius, O.; Markkula, G.: Bell-Shaped Steering Corrections (2014)**

Benderius, Ola; Markkula, Gustav: Evidence for a fundamental property of steering, in: Proceedings of the Human Factors and Ergonomics Society Annual Meeting (1), Jahrgang 58, S. 884–888, 2014

**Biral, F. et al.: Combining Safety and User Preferences (2005)**

Biral, F.; Da Lio, M.; Bertolazzi, E.: Combining safety margins and user preferences into a driving criterion for optimal control-based computation of reference maneuvers for an ADAS of the next generation, in: IEEE Proceedings. Intelligent Vehicles Symposium, 2005

**Biral, F. et al.: An intelligent curve warning system for powered two wheel vehicles (2010)**

Biral, Francesco; Da Lio, Mauro; Lot, Roberto; Sartori, Roberto: An intelligent curve warning system for powered two wheel vehicles, in: European Transport Research Review (3), Jahrgang 2, S. 147–156, 2010

**Biral, F.; Lot, R.: An interpretative model of g-g diagrams of racing motorcycle (2009)**

Biral, Francesco; Lot, Roberto: An interpretative model of g-g diagrams of racing motorcycle, in: Batra, Romesh C.; Qian, Linfang (Hrsg.): Proceedings of the third International Conference on Mechanical Engineering and Mechanics, Science Press, Monmouth Junction, NJ, 2009

**Bishop, C. M.: Pattern recognition and machine learning (2009)**

Bishop, Christopher M.: Pattern recognition and machine learning, Information science and statistics, 8. Auflage, Springer, New York, NY, 2009

**BMVI: Verkehrssicherheitsprogramm 2011-2020 (2015)**

BMVI: Halbzeitbilanz des Verkehrssicherheitsprogramms 2011-2020; <http://bmvi.de>, 2015, Zugriff 10.04.2018

**Borin, A.: SAFERIDER (2012)**

Borin, Andrea: SAFERIDER A Step forward in motorcycle safety, in: Motor Ring No. 34, 2012

**Bosetti, P. et al.: On the human control of vehicles (2014)**

Bosetti, Paolo; Da Lio, Mauro; Saroldi, Andrea: On the human control of vehicles, in: European Transport Research Review (2), Jahrgang 6, S. 157–170, 2014

**Bossdorf-Zimmer, J. et al.: Fingerprint des Fahrers (2011)**

Bossdorf-Zimmer, Janine; Kollmer Hermann; Henze, Roman; Küçükay, Ferit: Fingerprint des Fahrers zur Adaption von Assistenzsystemen, in: ATZ Automobiltechnische Zeitschrift (03), Jahrgang 113, S. 226–231, 2011

**Cáceres Hernández, D. et al.: Lane region detection (2016)**

Cáceres Hernández, Danilo; Kurnianggoro, Laksono; Filonenko, Alexander; Jo, Kang H.: Real-Time Lane Region Detection Using a Combination of Geometrical and Image Features, in: Sensors (Basel, Switzerland) (11), Jahrgang 16, 2016

**Chandrasiri, N. P. et al.: Driving Skill Classification in Curves (2016)**

Chandrasiri, Naiwala P.; Nawa, Kazunari; Ishii, Akira: Driving skill classification in curve driving scenes using machine learning, in: Journal of Modern Transportation (3), Jahrgang 24, S. 196–206, 2016

**Cordts, M. et al.: Cityscapes Benchmark Suite (2016)**

Cordts, M.; Omran, M.; Ramos, S.; Rehfeld, T.; Enzweiler, M.; Benenson, R.; Franke, U.; Roth, S.; Schiele, B.: Cityscapes Benchmark Suite; <https://www.cityscapes-dataset.com/benchmarks/>, 2016, Zugriff 09.04.2020

**Craen, S. de et al.: Effects of advanced rider training (2014)**

Craen, Saskia de; Boele-Vos, Marjolein; Everink, Arjan: Long-term effects of a one-day advanced rider training, in: Institut für Zweiradsicherheit (Hrsg.): Sicherheit, Umwelt, Zukunft, Forschungshefte Zweiradsicherheit Nr. 16, 1. Auflage, Ifz, Essen, 2014

**Crundall, D. et al.: Study on motorcycle experience and training (2014)**

Crundall, David; Stedmon, Alex W.; Crundall, Elizabeth; Saikayasit, Rossukorn: The role of experience and advanced training on performance in a motorcycle simulator, in: Accident; analysis and prevention, Jahrgang 73, S. 81–90, 2014

**Crundall, E. et al.: Experiential differences across rider groups (2012)**

Crundall, Elizabeth; Crundall, David; Stedmon, Alex W.: Negotiating left-hand and right-hand bends: a motorcycle simulator study to investigate experiential and behaviour differences across rider groups, in: PloS one (1), Jahrgang 7, 2012

**Daniello, A. et al.: Effectiveness of Motorcycle Training and Licensing (2009)**

Daniello, Allison; Gabler, Hampton; Mehta, Yusuf: Effectiveness of Motorcycle Training and Licensing, in: Transportation Research Record: Journal of the Transportation Research Board (2), Jahrgang 2140, S. 206–213, 2009

**Davy Neven et al.: Towards End-to-End Lane Detection: an Instance Segmentation Approach (2018)**

Davy Neven; Bert De Brabandere; Stamatios Georgoulis; Marc Proesmans; Luc Van Gool: Towards End-to-End Lane Detection: an Instance Segmentation Approach, in: CoRRabs/1802.05591, 2018

**D'Errico, J.: SLM - Shape Language Modeling Toolbox (2017)**

D'Errico, John: SLM - Shape Language Modeling Toolbox, 2017

**Destatis: Verkehr Verkehrsunfälle 2016 (2017)**

Statistisches Bundesamt (Hrsg.) Verkehr Verkehrsunfälle 2016, Fachserie 8 Reihe 7, Statistisches Bundesamt, Wiesbaden, 2017

**Destatis: Verkehrsunfälle Zeitreihen (2017)**

Statistisches Bundesamt (Hrsg.) Verkehrsunfälle Zeitreihen, Statistisches Bundesamt, Wiesbaden, 2017

**DIN ISO 8855:2013-11 Straßenfahrzeuge - Begriffe (2013)** DIN ISO 8855:2013-11, Straßenfahrzeuge\_ - Fahrzeugdynamik und Fahrverhalten\_ - Begriffe (ISO\_8855:2011), Beuth Verlag GmbH, Berlin, 2013

**Donges, E.: Drei-Ebenen Modell der Fahrzeugführung (1982)**

Donges, Edmund: Aspekte der Aktiven Sicherheit bei der Führung von Personenkraftwagen, in: Automobil Industrie (27), S. 156–162, 1982

**Donges, E.: Fahrerverhaltensmodelle (2015)**

Donges, Edmund: Fahrerverhaltensmodelle, in: Winner, Hermann et al. (Hrsg.): Handbuch Fahrerassistenzsysteme, Springer Fachmedien Wiesbaden, Wiesbaden, 2015

**European Commission: Towards European road safety (2010)**

European Commission: Towards a European road safety area: policy orientations on road safety 2011-2020, COM(2010) 389 final, Brussels, 2010

**Fisher, R. A.: Diskriminanzanalyse (1936)**

Fisher, Ronald A.: The Use of Multiple Measurements in Taxonomic Problems, in: Annals of Eugenics (2), Jahrgang 7, S. 179–188, 1936

**GDV: Verbesserung der Motorradsicherheit (2017)**

GDV: Intelligente Systeme zur Verbesserung der Motorradsicherheit, Berlin, 2017

**Gensler, A.; Sick, B.: Criteria to Measure TS Segmentation (2014)**

Gensler, Andre; Sick, Bernhard: Novel Criteria to Measure Performance of Time Series Segmentation Techniques, in: Proceedings of the 16th LWA Workshops: KDML, IR and FGWM, Aachen, Germany, September 8-10, 2014, 2014

**Grimme, B. et al.: Naturalistic arm movements during obstacle avoidance in 3D and the identification of movement primitives (2012)**

Grimme, Britta; Lipinski, John; Schöner, Gregor: Naturalistic arm movements during obstacle avoidance in 3D and the identification of movement primitives, in: Experimental brain research (3), Jahrgang 222, S. 185–200, 2012

**Hengshuang Zhao et al.: Pyramid Scene Parsing Network (2016)**

Hengshuang Zhao; Jianping Shi; Xiaojuan Qi; Xiaogang Wang; Jiaya Jia: Pyramid Scene Parsing Network, in: CoRRabs/1612.01105, 2016

**Hubert, L.; Arabie, P.: Comparing partitions (1985)**

Hubert, Lawrence; Arabie, Phipps: Comparing partitions, in: Journal of Classification (1), Jahrgang 2, S. 193–218, 1985

**Institut für Zweiradsicherheit: Sicherheit, Umwelt, Zukunft (2014)**

Institut für Zweiradsicherheit (Hrsg.) Sicherheit, Umwelt, Zukunft, Forschungshefte Zweiradsicherheit, Jahrgang 16, 1. Auflage, Ifz, Essen, 2014

**IPG Automotive GmbH: IPGDriver User Manual 6.5 (2015)**

IPG Automotive GmbH: IPGDriver User Manual 6.5; [www.ipg.de](http://www.ipg.de), 2015

**Juang, B.-H.; Rabiner, L. R.: Probabilistic Distance for HMM (1985)**

Juang, B.-H.; Rabiner, L. R.: A Probabilistic Distance Measure for Hidden Markov Models, in: AT&T Technical Journal (2), Jahrgang 64, S. 391–408, 1985

**Kagawa, T.; Chandrasiri, N. P.: Deep Learning Driving Skills in Curves (2017)**

Kagawa, Takuya; Chandrasiri, Naiwala P.: Analysis of Driving Skills based on Deep Learning using Stacked Autoencoders, in: 2017 4th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI), 19-21 Sept. 2017

**Kaufman, L.; Rousseeuw, P. J.: Finding Groups in Data (2009)**

Kaufman, Leonard; Rousseeuw, Peter J.: Finding Groups in Data, Wiley Series in Probability and Statisticsv.344, 99. Auflage, John Wiley & Sons Inc, Hoboken, 2009

**Kroll, A.: Computational Intelligence (2016)**

Kroll, Andreas: Computational Intelligence, De Gruyter Studium, 2. Auflage, De Gruyter Oldenbourg, Berlin, Boston, 2016

**Liers, H. et al.: Analysis of PTW Accidents in GIDAS (2014)**

Liers, Henrik; Hannawald, Lars; Prohn, Maria: Analysis of the accident scenario of powered two-wheelers on the basis of real accidents, in: Institut für Zweiradsicherheit (Hrsg.): Sicherheit, Umwelt, Zukunft, Forschungshefte Zweiradsicherheit Nr. 16, 1. Auflage, Ifz, Essen, 2014

**Lin, W. C. et al.: Characterization of Driving Skill Level (2007)**

Lin, William C.; Chin, Yuen K.; Repa, Brian S.; Lu, Manxue; Nisonger, Robert L.; Liang, Cwo G.: Characterisation of driving skill level using driving simulator tests, in: International Journal of Vehicle Autonomous Systems 3/4, Jahrgang 5, S. 219, 2007

**Lindner, P. et al.: Robust geometric lane feature extraction (2010)**

Lindner, Philipp; Blokzyl, Stephan; Wanielik, Gerd; Scheunert, Ullrich: Applying multi level processing for robust geometric lane feature extraction, in: 2010 IEEE Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI 2010), IEEE, Piscataway, NJ, 2010

**Magiera, N. et al.: Probabilistic Segmentation into Maneuver Primitives**

Magiera, N.; Janssen, H.; Heckmann, M.; Winner, H.: Rider skill identification by probabilistic segmentation into motorcycle maneuver primitives, in: 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)

**Magiera, N. et al.: Methoden zur Schätzung von Fahrfertigkeiten (2016)**

Magiera, Nils; Winner, Hermann; Janssen, Herbert; Heckmann, Martin: Ein Ansatz zur Schätzung der Fahrfertigkeiten - Überblick über Methoden und Ergebnisse, in: Institut für Zweiradsicherheit (Hrsg.): Sicherheit, Umwelt, Zukunft, Forschungshefte Zweiradsicherheit Nr. 17, 1. Auflage, Institut für Zweiradsicherheit e.V, Essen, 2016

**Markkula, G.: Driver behavior models for evaluating automotive active safety (2015)**

Markkula, Gustav: Driver behavior models for evaluating automotive active safety, Doktorsavhandlingar vid Chalmers Tekniska Högskola N.S., 3834, Chalmers Univ. of Technology, Göteborg, 2015

**Mataric, M. J.: Sensory-Motor Primitives (2002)**

Mataric, Maja J.: Sensory-Motor Primitives as a Basis for Imitation: Linkin Perception to Action and Biology to Robotics, in: Dautenhahn, K.; Nehaniv, C. (Hrsg.): Imitation in Animals and Artifacts, MIT Press, Cambridge, MA, USA, 2002

**Morasso, P.: Spatial control of arm movements (1981)**

Morasso, P.: Spatial control of arm movements, in: Experimental Brain Research (2), Jahrgang 42, 1981

**Murphey, Y. L. et al.: Driver's style classification using jerk analysis (2009)**

Murphey, Yi L.; Milton, Robert; Kiliaris, Leonidas: Driver's style classification using jerk analysis, in: IEEE Workshop on Computational Intelligence in Vehicles and Vehicular Systems, 2009, IEEE, Piscataway, NJ, 2009

**Murphy, K. P.: Machine learning (2012)**

Murphy, Kevin P.: Machine learning, Adaptive computation and machine learning series, MIT Press, Cambridge, Mass., 2012

**Osgouei, R. H. et al.: HMM based Driving Skill Measure (2013)**

Osgouei, Reza H.; Lee, Hojin; Choi, Seungmoon: Comparative evaluation of performance measures for human driving skills, in: Intelligent Service Robotics (4), Jahrgang 6, S. 169–180, 2013

**Rabiner, L. R.: A Tutorial on HMM (1989)**

Rabiner, L. R.: A tutorial on hidden Markov models and selected applications in speech recognition, in: Proceedings of the IEEE (2), Jahrgang 77, S. 257–286, 1989

**Rand, W. M.: Objective Criteria for the Evaluation of Clustering Methods (1971)**

Rand, William M.: Objective Criteria for the Evaluation of Clustering Methods, in: Journal of the American Statistical Association (336), Jahrgang 66, S. 846, 1971

**Rasmussen, J.: Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models (1983)**

Rasmussen, Jens: Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models, in: IEEE Transactions on Systems, Man, and Cybernetics (3) SMC-13, S. 257–266, 1983

**Rice, R. S.: Measuring Car-Driver Interaction with the g-g Diagram (1973)**

Rice, R. S.: Measuring Car-Driver Interaction with the g-g Diagram, in: 1973 International Automotive Engineering Congress and Exposition, SAE Technical Paper Series, SAE International 400 Commonwealth Drive, Warrendale, PA, United States, 1973

**Runkler, T. A.: Data Mining (2010)**

Runkler, Thomas A.: Data Mining, Computational intelligence, Vieweg + Teubner, Wiesbaden, 2010

**Schröter, K. G.: Dissertation, Brake steer torque optimized corner braking motorcycles (2014)**

Schröter, Kai G.: Brake steer torque optimized corner braking motorcycles, Dissertation, 2014

**Shun-Zheng Yu; Kobayashi, H.: An efficient forward-backward algorithm for an explicit-duration hidden Markov model (2003)**

Shun-Zheng Yu; Kobayashi, H.: An efficient forward-backward algorithm for an explicit-duration hidden Markov model, in: IEEE Signal Processing Letters (1), Jahrgang 10, S. 11–14, 2003

**Shun-Zheng Yu; Kobayashi, H.: Practical implementation of an efficient forward-backward algorithm for an explicit-duration hidden Markov model (2006)**

Shun-Zheng Yu; Kobayashi, H.: Practical implementation of an efficient forward-backward algorithm for an explicit-duration hidden Markov model, in: IEEE Transactions on Signal Processing (5), Jahrgang 54, S. 1947–1951, 2006

**Spiegel, B.: Die obere Hälfte des Motorrads (2009)**

Spiegel, Bernt: Die obere Hälfte des Motorrads, Motorbuch-Verl., Stuttgart, 2009

**Tang, X.: Driving Skill Recognition and Comparison (2009)**

Tang, Xidong: Driving skill recognition: New approaches and their comparison, in: American Control Conference, 2009, IEEE, Piscataway, NJ, 2009

**Wang, Y. et al.: Lane detection and tracking using B-Snake (2004)**

Wang, Yue; Teoh, Eam K.; Shen, Dinggang: Lane detection and tracking using B-Snake, in: Image and Vision Computing (4), Jahrgang 22, S. 269–280, 2004

**Ward, J. H., JR.: Hierarchical grouping (1963)**

Ward, Joe H., JR.: Hierarchical grouping to optimize an objective function, in: Journal of the American Statistical Association : JASA 58 (1963), S. 236–244, 1963

**Weidele, A.: Untersuchungen zum Bremsverhalten von Motorrädern unter besonderer Berücksichtigung der ABS-geregelten Kurvenbremsung (1994)**

Weidele, Alois: Untersuchungen zum Bremsverhalten von Motorrädern unter besonderer Berücksichtigung der ABS-geregelten Kurvenbremsung, Berichte aus dem Fachgebiet Fahrzeugtechnik der TH Darmstadt, Jahrgang 210, VDI-Verl., Düsseldorf, 1994



**Xingang Pan et al.: Spatial As Deep: Spatial CNN for Traffic Scene Understanding (2017)**

Xingang Pan; Jianping Shi; Ping Luo; Xiaogang Wang; Xiaoou Tang: Spatial As Deep: Spatial CNN for Traffic Scene Understanding, in: CoRRabs/1712.06080, 2017

**Xsens Technologies B.V.: MTi User Manual (2015)**

Xsens Technologies B.V.: MTi User Manual; [www.xsens.com](http://www.xsens.com), 2015

**Yoneta, K. et al.: Offenlegung Motorcycle Rider Assessment Device (2010)**

Yoneta, Keisuke; Daimoto, Hiroshi; Yamamoto, Atsuo: Rider Characteristics Assessment Device and Straddle-Ridden Vehicle Provided Therewith, Grünecker, Kinkeldey, Stockmair & Schwanhäusser, Patent EP2517952A1, Patent Anmeldenummer: 10838878.6, 2010

**Zhang, Y. et al.: Driving Skill Characterization (2010)**

Zhang, Yilu; Lin, William C.; Chin, Yuen-Kwok S.: A Pattern-Recognition Approach for Driving Skill Characterization, in: IEEE Transactions on Intelligent Transportation Systems (4), Jahrgang 11, S. 905–916, 2010

---

## Eigene Veröffentlichungen

### **Magiera, N. et al.: Probabilistic Segmentation into Maneuver Primitives**

Magiera, N.; Janssen, H.; Heckmann, M.; Winner, H.: Rider skill identification by probabilistic segmentation into motorcycle maneuver primitives, in: 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)

### **Magiera, N. et al.: Methoden zur Schätzung von Fahrfertigkeiten (2016)**

Magiera, Nils; Winner, Hermann; Janssen, Herbert; Heckmann, Martin: Ein Ansatz zur Schätzung der Fahrfertigkeiten - Überblick über Methoden und Ergebnisse, in: Institut für Zweiradsicherheit (Hrsg.): Sicherheit, Umwelt, Zukunft, Forschungshefte Zweiradsicherheit Nr. 17, 1. Auflage, Institut für Zweiradsicherheit e.V, Essen, 2016

### **Magiera, N. et al.: Method for analyzing rider performance (2017)**

Magiera, Nils; Heckmann, Martin; Janssen, Herbert; Winner, Hermann: Method, system and vehicle for analyzing a rider performance, Honda Research Institute Europe GmbH, Patent US10421464B2, Patent Anmeldenummer: US20170259829A1, 2017

---

## Betreute studentische Arbeiten

**Albrecht, Alexander:** Entwicklung und Implementierung eines Bayes'schen Algorithmus zur Messdatensegmentierung. Bachelorthesis Nr. 1249/15. 2015

**Döring, Simon Felix:** Entwicklung und Implementierung eines Frameworks zur Bewertung der Performance von Algorithmen zur Messdatensegmentierung. Bachelorthesis Nr. 1235/15. 2015

**Friedrichs, Kersten:** Untersuchung des Potentials von Motorraddynamikmodellen zur Ermittlung von Fahrereingabegrößen während querdynamischer Fahrmanöver. Masterthesis Nr. 576/15. 2015

**Graßmuck, Yannic:** Modellierung der transienten Rollbewegung eines Motorrads beim Ein- und Austritt einer Kurve. Bachelorthesis Nr. 1241/15. 2015

**Häffner, Nicolas:** Analyse der Stabilität eines Motorrads im Niedriggeschwindigkeitsbereich. Bachelorthesis Nr. 1245/15. 2015

**Hellmann, Adrian:** Untersuchung zur Reproduzierbarkeit und Vergleichbarkeit von Motorrad-Messfahrten im Realverkehr, Masterthesis Nr. 543/14. 2014

**Kowalczyk, Christian:** Entwicklung einer Systematik für Fahrfehler sowie Analyse der Auswirkung von Manöverparameter auf die Identifizier- und Klassifizierbarkeit anhand ausgewählter Versuche. Bachelorthesis Nr. 1221/15. 2015

**Müller, Annelie:** Vergleich verschiedener Human-Machine-Interface-Möglichkeiten für die Empfehlungsausgabe eines Fahrerassistenzsystems. Masterthesis Nr. 649/17. 2017

**Noutangnin, Yves:** Umsetzung und Evaluation einer verbesserten Methode zur Kompensation von Latenzen zwischen Messung und Messwertverfügbarkeit in einem Fusionsfilter zur Selbstlokalisierung. Masterthesis Nr. 608/16. 2016

**Rohrmüller, Lukas:** Bewertung von Motorrad-Kurvenfahrten anhand der Fahrzeugtrajektorie und des Fahrstreifenverlaufs. Bachelorthesis Nr. 1285/16. 2016

**Surek, Daniel:** Umsetzung und Evaluation von Fehlerkorrektur- und Detektionsmethoden für einen barometrischen Hözensensor in einem Fusionsfilter zur Selbstlokalisierung. Nr. 599/15. 2015

**Winkler, Nico:** Recherche und Bewertung des Standes der Forschung zur Modellierung der Fertigkeiten und des Verhaltens von Fahrzeugführern im Realverkehr. Bachelorthesis Nr. 1210/14.